

DOI:10.3880/j.issn.1004-6933.2023.06.002

# 基于 LSTM-GM 神经网络模型的风暴潮增水预报方法

苑希民<sup>1</sup>, 黄玉啟<sup>2</sup>, 田福昌<sup>1</sup>, 曹鲁赣<sup>1</sup>

(1. 天津大学水利工程仿真与安全国家重点实验室, 天津 300072;  
2. 浙江省水利水电勘测设计研究院有限责任公司, 浙江 杭州 310002)

**摘要:**为充分挖掘风暴潮增水的时序关联特性,提高风暴潮增水的预报精度,综合考虑台风因素、气象要素和天文潮因素对风暴潮增水的影响,结合长短期记忆(LSTM)神经网络和灰色模型(GM)的优势,提出基于 LSTM-GM 神经网络模型的风暴潮增水预报方法。利用该方法采用 12 场历史台风数据对小清河入海口风暴潮增水进行模拟预报,并将预报结果与 LSTM 神经网络、BP 神经网络的预报结果进行对比。结果表明:相较于 LSTM 神经网络和 BP 神经网络,LSTM-GM 神经网络模型的纳什效率系数分别提高了 6.5% 和 11.4%,均方根误差分别降低了 70.6% 和 72.2%,平均相对误差分别降低了 50% 和 69.2%;LSTM-GM 神经网络模型可有效处理风暴潮增水与各影响因素间的非线性关系,提高风暴潮增水预报的精度。

**关键词:**风暴潮增水;LSTM-GM 神经网络模型;GM 误差修正;小清河入海口

**中图分类号:**P731.34      **文献标志码:**A      **文章编号:**1004-6933(2023)06-0008-08

**Research on forecasting method of storm surge based on LSTM-GM neural network model//YUAN Ximin<sup>1</sup>, HUANG Yuqi<sup>2</sup>, TIAN Fuchang<sup>1</sup>, CAO Luguang<sup>1</sup> (1. State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300072, China; 2. Zhejiang Design Institute of Water Conservancy and Hydroelectric Power Co., Ltd., Hangzhou 310002, China)**

**Abstract:** In order to fully explore the time series correlation characteristics of storm surge and improve the forecast accuracy of storm surge, this paper comprehensively considered the influence of typhoon, meteorological and astronomical tide factors on storm surge, combined the advantages of long short term memory (LSTM) neural network and gray model (GM), and proposed a forecasting method of storm surge based on LSTM-GM neural network model. Using this method, 12 historical typhoon data were used to simulate and forecast the storm surge in the Xiaoqing River Estuary, and the forecast results were compared with the prediction results of the LSTM neural network and the BP neural network. The results showed that compared to LSTM neural network and BP neural network, the NSE index of LSTM-GM neural network model increased by 6.5% and 11.4%, RMSE decreased by 70.6% and 72.2%, and MAPE decreased by 50% and 69.2%, respectively. The LSTM-GM neural network model can effectively handle the nonlinear relationship between storm surge and various influencing factors, and improve the accuracy of storm surge forecast.

**Key words:** storm surge; LSTM-GM neural network model; GM error correction; Xiaoqing River Estuary

风暴潮是一种由于强风和气压骤变等剧烈的大气扰动,导致海水升降异常的自然灾害现象<sup>[1]</sup>。风暴潮灾害是我国主要海洋灾害之一,其成灾频率高,致灾强度大,给沿海经济发展和人民生命财产安全带来巨大威胁。据 2010—2020 年《中国海洋灾害公

报》<sup>[2]</sup> 数据统计,我国沿海共发生风暴潮过程 194 次,其中致灾 94 次,累计死亡(含失踪)64 人,直接经济损失达 874 亿元,约占海洋灾害直接经济总损失的 86.6%。因此,开展风暴潮增水预报研究对提升沿海防灾减灾能力和保障沿海人民生命财产安全

**基金项目:**国家重点研发计划项目(2018YFC1508403);国家自然科学基金委创新团队项目(51621092);科技部重点领域创新团队项目(2014RA4031);天津大学自主创新基金项目(2022XHX-0013,2022XSU-0019)

**作者简介:**苑希民(1968—),男,教授,博士,主要从事防洪减灾与智慧水利研究。E-mail: yxm@tju.edu.cn

**通信作者:**田福昌(1989—),男,助理研究员,博士,主要从事防洪减灾与应急决策研究。E-mail: tianfuchang@tju.edu.cn

具有重要意义。

目前,风暴潮增水预报方法主要分为经验统计预报、数值模拟预报以及人工智能预报3种。经验统计预报利用数理统计方法建立监测站当地气象特征与特定港口风暴潮增水值之间的经验预报方程,如罗志发等<sup>[3-4]</sup>基于监测站点多年历史潮位资料研究其风暴潮的基本特征,并通过线性拟合,得到监测站点的风暴潮经验预报公式。数值模拟预报包括数值天气预报和风暴潮数值计算,如苑希民等<sup>[5]</sup>联合不同维度水动力数值模型计算优势,建立漫溃堤洪水多维耦联数值仿真模型,精确模拟了洪水演进变化规律及分流特征,为风暴潮数值模型计算提供了新思路;蒋昌波等<sup>[6-8]</sup>综合考虑了地形因素和台风因素的影响,利用 ADCIRC (advanced circulation) 模型和 SWAN (simulating waves nearshore) 模型建立了风暴潮与天文潮耦合的数值预报模型。然而,经验统计预报过分依赖历史数据,且预报方程仅适用于特定港口;数值模拟预报需对风暴潮增水的生成机制和传播过程进行准确模拟,但由于风暴潮增水的内部物理机制和动力学规律复杂,很难建立起准确稳定的预报模型。随着人工智能的发展,以人工神经网络 (artificial neural network, ANN) 为代表的机器学习算法由于具有较强的非线性拟合和自适应能力,已被广泛应用于水文预报领域<sup>[9-10]</sup>。例如:卢君峰等<sup>[11]</sup>综合考虑了风暴潮增水的主要影响因素,利用 BP 神经网络对厦门沿岸的风暴潮增水进行预报;周寅杰等<sup>[12]</sup>建立了基于被囊群算法优化的 BP 神经网络模型,并将其应用于温州站风暴潮增水预报中;刘媛媛等<sup>[13-14]</sup>将风速、风向、气压和前时序潮位等要素作为输入对长短期记忆 (long short-term memory, LSTM) 神经网络进行训练,建立了风暴潮增水的临近预报模型;Tseng 等<sup>[15]</sup>考虑了台风因素和地理因素对风暴潮增水的影响,利用 BP 神经网络构建了适用于台湾东北部沿海的风暴潮增水预报模型;Sahoo 等<sup>[16-17]</sup>均使用人工神经网络对风暴潮增水进行预报;朱佩京等<sup>[18]</sup>综合考虑了台风风暴潮增水的7个影响因素,利用随机森林模型对风暴潮增水进行预报;姚炜<sup>[19]</sup>利用 TCRM (tropical cyclone risk model) 和 GOMO (generalized operator model of the ocean) 合成台风风暴潮数据集,并利用 LSTM 对南海北部沿岸的风暴潮增水进行预报;吕忻等<sup>[20]</sup>通过3折滑动时间序列交叉验证结合网格搜索方法确定 LSTM 的最佳参数,构建了吴淞口潮位预报模型;苗庆生等<sup>[21]</sup>利用信息流理论确定了风暴潮增水的影响因素,并利用 LSTM 对厦门风暴潮增水进行预报;薛明等<sup>[22]</sup>利用 BP 神经网络、小波神经网络、递

归神经网络进行风暴潮增水值预测。上述人工智能预报方法的研究,部分只考虑了风暴潮增水数据与其影响因素间的静态关系,没有充分挖掘风暴潮增水的时序关联特性;部分虽然综合考虑了风暴潮增水的影响因素及其时序关联性,但预报精度有待进一步完善。

为了克服现有风暴潮增水预报方法的不足,本文综合考虑台风因素、气象要素和天文潮因素对风暴潮增水的影响,结合 LSTM 神经网络泛化能力好、非线性预报准确率高的优势以及灰色模型 (gray model, GM) 可弱化数据的波动性和随机性的优势,提出一种基于 LSTM-GM 神经网络模型的风暴潮增水预报方法。由于特殊的地理位置和水文气象等条件影响,小清河入海口风暴潮灾害频发,灾害损失严重。因此选取小清河入海口的风暴潮增水预报为例,运用该组合模型进行风暴潮增水预报,并将预报结果与 LSTM 神经网络和 BP 神经网络的预报结果对比,对 LSTM-GM 神经网络模型进行验证。


## 1 预报方法

### 1.1 LSTM 神经网络

LSTM 神经网络是一种基于递归神经网络 (recursive neural network, RNN) 的机器学习算法,其通过独特的门控设计进行信息传递,信息传递机制更为精细,能够充分挖掘序列数据的长期依赖关系,可有效避免长序列训练过程中的梯度消失和梯度爆炸问题<sup>[23-24]</sup>。LSTM 神经网络由输入层、隐藏层、全连接层和输出层组成,其中隐藏层是链状结构,主要包括输入门、输出门、遗忘门和记忆模块,其模型结构如图1所示。

### 1.2 灰色模型

灰色系统理论通过对原始数据的整理和分析来挖掘离散数据间的规律性,将杂乱无章的离散数据转换为有较强规律的新数据序列,进而建立起相应微分方程形式的模型,其可有效处理数据的波动性和随机性问题。灰色模型是灰色系统理论的重要组成部分,其在充分认识和鉴别系统内各因素间不确定性关系和相异程度的基础上,利用建立起的微分方程充分挖掘系统本质,进而对系统未来发展趋势进行预测,适用于处理数据波动较大和信息不全等不确定性问题<sup>[25]</sup>。改进的 GM(1,1) 模型主要包括新信息 GM(1,1) 模型 (预测出的数据作为原始变量数据,递推预测数据)<sup>[26]</sup> 和新陈代谢 GM(1,1) 模型 (预测出的数据作为原始变量数据,同时去掉最老的数据,递推预测数据)<sup>[27]</sup>,其利用新信息替换旧信息,保持模型在预报过程中的动态更新。



注:  $i_t$ 、 $f_t$ 、 $o_t$  分别为输入门限、遗忘门限和输出门限;  $\sigma$  为 Sigmoid 激活函数;  $C_t$  为  $t$  时刻的单元内部状态;  $\hat{C}_t$  为  $t$  时刻的单元候选状态;  $h_t$  为  $t$  时刻的单元外部状态。

图 1 LSTM 神经网络结构

Fig. 1 Structure of LSTM neural network

### 1.3 预报流程

为提升风暴潮增水的预报精度,将 LSTM 神经网络和灰色模型的优势相结合,构建 LSTM-GM 神经网络模型,并提出基于 LSTM-GM 神经网络模型的风暴潮增水预报方法,其预报流程(图 2)主要包括风暴潮增水影响因素分析、数据预处理、LSTM 神经网络参数设置、灰色模型误差修正以及模型性能评估等。




图 2 LSTM-GM 神经网络模型预报流程

Fig. 2 Forecast flow of LSTM-GM neural network model

a. 风暴潮增水影响因素分析。风暴潮增水内部物理机制和动力学规律复杂,主要受台风、气象、天文潮、地理和潮流波浪等多种因素影响<sup>[3,11]</sup>,各影响因素间存在着复杂的非线性关系,且随机性强。台风因素主要包括台风中心位置、台风风力风速、台

风中心气压、台风移速移向以及台风风圈半径等台风自身特征;气象要素主要包括台风影响期间测站当地的风向、风速和气压等气象特征;地理因素主要包括测站位置、坡度以及海岸形状和海底地形等地理特征。对于特定监测站点,地理特征的变化通常较小,对风暴潮增水的影响可忽略不计。然而,在台风影响期间,台风自身特征以及测站当地气象特征的变化是显著的,且当风暴潮与天文潮同时发生时可能会引起部分地区水位暴增,引发巨大潮灾。因此,台风因素、气象要素和天文潮因素对风暴潮增水的影响是不可忽略的。

b. 数据预处理。数据预处理是为了提高模型的收敛速度和预报精度,避免不同指标数值区间的差异性,消除不同量纲对预报结果的影响。采用 mapmaxmin 函数<sup>[11]</sup>对风暴潮增水及各影响因素监测数据进行归一化处理,经处理后的指标数值按固定比例缩放至  $[0,1]$  范围内。归一化公式为

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min} \quad (1)$$

式中:  $y$  为风暴潮增水及各影响因素监测值归一化的值;  $x_{\max}$ 、 $x_{\min}$  分别为风暴潮增水及各影响因素监测值对应的最大值和最小值;  $y_{\max}$ 、 $y_{\min}$  分别为  $x_{\max}$  和  $x_{\min}$  归一化后对应的最大值和最小值;  $x$  为风暴潮增水及各影响因素监测值。

c. LSTM 神经网络参数设置。影响 LSTM 神经网络模型训练效果的关键参数主要有学习率、隐藏层神经元个数、批尺寸和迭代次数等。其中,学习率控制模型更新方向与收敛速度;隐藏层神经元个数决定模型的非线性拟合能力;批尺寸主要影响模型训练速度;迭代次数主要影响权值更新的效率。

通常将平均绝对误差(MAE)设为损失函数,即通过预报值与监测值的MAE对模型进行训练。为保证模型的鲁棒性和使损失函数最小,采用基于自适应学习原理的Adam算法优化LSTM神经网络内部参数,通过网格搜索法确定模型的关键参数。

d. 利用灰色模型修正LSTM神经网络的误差。将LSTM神经网络训练样本预报值与监测值相比较得到的训练样本误差序列作为灰色模型的原始数据序列,利用灰色模型弱化误差序列数据间的随机波动性,挖掘误差系列的规律,从而对预报误差进行修正。本文选用传统GM(1,1)模型、新信息GM(1,1)模型和新陈代谢GM(1,1)模型分别对LSTM神经网络模型的预报误差进行修正,选用修正后预报误差最小的模型进行风暴潮增水预报。最后,将满足精度要求的预报结果进行反归一化处理得到风暴潮增水值。

e. 模型性能评估。风暴潮增水是一种典型的时间序列问题,对风暴潮增水预报模型性能的评估不仅应考虑模型总体稳定和平均误差,还应考虑最大增水值间的误差。本文采用纳什效率系数(NSE)、均方根误差(RMSE)、平均相对误差(MAPE)和最大增水值相对误差( $\Delta y_p$ )等评估指标从鲁棒性和泛化性等方面对不同预报模型的性能进行评估。其中,NSE常用来量化水文预报模型的预报精度,反映监测增水值与预报增水值之间的一致性,NSE越接近于1代表一致性程度越高,模型预报效果越好;RMSE和MAPE反映监测增水值与预报增水值之间的差异程度,RMSE和MAPE越小代表模型预报精度越高。

## 2 实例验证

### 2.1 研究区概况

小清河发源于山东省济南市南部山区,自西向东流经济南、滨州、淄博、东营和潍坊5市,于寿光市羊口镇东注入渤海莱州湾<sup>[28]</sup>,小清河入海口位置分布如图3所示,入海口沿海天文潮属“一日两潮”的不规则半日潮区。根据1951—2021年小清河入海口潮位观测资料分析,多年风暴潮增水的最大值为3.83 m,最小值为1.89 m,平均风暴潮增水为2.45 m。由于小清河入海口频繁发生大流量洪水,寿光市成为我国北方地区遭受风暴潮灾害最严重的地区之一,因此开展小清河入海口风暴潮增水预报研究对提升寿光市海洋预报减灾能力有重要的现实意义。




图3 小清河入海口位置

Fig.3 Location of Xiaoqing River Estuary

### 2.2 数据来源

采用数据包括台风因素数据、气象要素数据和天文潮因素数据。台风因素数据为2000—2021年洋口港导致小清河入海口风暴潮增水的12场历史台风数据(表1),台风中心的最大风速、最低气压、最大风速半径和台风中心距羊口港测站的最短距离等具体特征数据来源于中国气象局热带气旋中心(<http://tcdata.typhoon.org.cn/>);气象要素数据包括台风影响期间羊口港测站(37°16'12"N,118°58'38"E)的风向、风速和气压数据,来源于美国国家海洋和大气管理气象数据中心(<https://www.ncdc.noaa.gov/data-access>);天文潮数据为台风影响期间羊口港测站的监测数据,来源于国家海洋信息中心(<http://www.nmdis.org.cn/>)。

表1 羊口港历史台风特征

Table 1 Historical typhoon characteristics of Yangkou Port

| 台风编号 | 台风名称 | 风暴潮增水最大值/m | 最大增水出现时间   |
|------|------|------------|------------|
| 0108 | 桃芝   | 2.51       | 2001-08-01 |
| 0209 | 风神   | 2.62       | 2002-07-25 |
| 0420 | 海马   | 2.43       | 2004-09-15 |
| 0509 | 麦莎   | 2.63       | 2005-08-06 |
| 1105 | 米雷   | 2.30       | 2011-06-23 |
| 1210 | 达维   | 2.62       | 2012-08-03 |
| 1410 | 麦德姆  | 2.54       | 2014-07-24 |
| 1810 | 安比   | 2.42       | 2018-07-23 |
| 1814 | 摩羯   | 2.63       | 2018-08-12 |
| 1818 | 温比亚  | 2.32       | 2018-08-19 |
| 1909 | 利奇马  | 2.37       | 2019-08-11 |
| 2106 | 烟花   | 2.49       | 2021-07-28 |

### 2.3 模型结构与参数确定

利用收集到的台风因素数据(台风中心的最大风速、最低气压、最大风速半径和台风中心距羊口港测站的最短距离)、气象要素数据(台风影响期间羊口港测站的风向、风速和气压)以及天文潮因素数据(台风影响期间羊口港测站的天文潮)作为组合预报模型的输入样本,风暴潮增水作为组合预报模型的输出样本,构建多因素输入、单因素输出的LSTM-GM神经网络模型。将表1中前10场历史台

风数据资料作为组合预报模型训练集,1909 号利奇马台风数据资料作为组合预报模型测试集,2106 号烟花台风数据资料作为组合预报模型预报集。从每个参与训练的历史台风数据资料中选取台风登陆前 72h 逐时的台风因素资料、台风影响期间羊口港的气象要素和天文潮因素资料组成输入训练集,选取对应时间羊口港的风暴潮增水值作为输出训练集,共 720 个训练模型对;按同样的方法,从利奇马台风数据资料选取台风登陆前 72h 逐时的各影响因素资料,组成 72 个测试模型对,并对烟花台风期间风暴潮增水进行预报。

通过不同参数设置以及逐参数微调进行模型的反复训练与测试,确定学习率为 0.1、时间步长为 1、隐藏层神经元个数为 17、批尺寸为 2、迭代次数为 300 作为该模型的最佳参数组合对训练集样本进行训练。为了提高组合模型的泛化能力,防止模型出现过拟合问题,本文运用 dropout 正则化算法,在每次训练过程中按 5% 的比例随机丢弃神经元,以此降低神经元间的协同性。

利用由最佳参数组合驱动的 LSTM 神经网络模型对风暴潮增水进行预报,将预报误差序列分别输入传统 GM(1,1)模型、新信息 GM(1,1)模型、新陈代谢 GM(1,1)模型进行修正,得到修正后预报误差平方和分别为 0.244、0.242、0.241 m。选取修正后预报误差最小的新陈代谢 GM(1,1)模型对风暴潮增水进行预报,其由最小二乘法拟合得到的发展系数  $\alpha$  为 0.009,灰色作用量  $\mu$  为 -0.012。其中,模型的训练误差和测试误差如图 4 所示,可见,当迭代次数达到 250 时,该组合模型的训练误差和测试误差都稳定在 0.04 m,说明模型没有出现拟合或欠拟合问题。图 5 为该组合模型训练过程中,风暴潮增水实测值和拟合值的对比曲线,可见,该模型在训练集上具有良好的拟合效果且预报误差很小,平均绝对误差在 0.12 m 之内,满足模型的预报精度要求。




图 4 模型的训练误差和测试误差

Fig. 4 Training error and verification error of model




图 5 风暴潮增水实测值与拟合值对比

Fig. 5 Comparison of measured values and fitted values of storm surge

## 2.4 预报结果对比与分析

为了分析不同因素对风暴潮增水预报的影响情况,将台风因素、气象要素和天文潮因素进行组合,形成以下 4 种影响因素组合情况:情况 1 仅考虑台风因素影响;情况 2 考虑台风因素和气象要素影响;情况 3 考虑台风因素和天文潮因素影响;情况 4 考虑台风因素、气象要素和天文潮因素影响。利用 LSTM-GM 神经网络模型对上述 4 种影响因素组合下的风暴潮增水值进行预报,并对每种情况下的 RMSE 进行比较,得到情况 1 ~ 4 下预报结果的 RMSE 分别为 0.056、0.048、0.045 和 0.035,考虑不同影响因素的预报结果对比如图 6 所示。可见,仅考虑台风因素影响的预报误差最大,综合考虑台风因素、气象要素和天文潮因素影响的预报误差最小。因此,本文综合考虑台风因素、气象要素和天文潮因素对风暴潮增水的影响,将其作为组合预报模型的输入样本进行训练是合理的。




图 6 考虑不同影响因素的预报结果对比

Fig. 6 Comparison of forecast results considering different influencing factors

为验证 LSTM-GM 神经网络模型的优越性和有效性,将 LSTM 神经网络与 BP 神经网络运用于风暴潮增水预报中,并将其预报结果与 LSTM-GM 神经网络模型的预报结果进行对比,利奇马台风和烟花台风影响期间风暴潮增水预报结果对比如图 7 所示。BP 神经网络适用于处理内部物理机制复杂以及影响因素间随机性强等问题,已被广泛应用于水科学研究领域,且对风暴潮增水预报具有一定的准确性和稳定性<sup>[29-32]</sup>。本文采用与 LSTM 神经网络具

有相同隐藏层单元的 BP 神经网络进行风暴潮增水预报,均由 8 个输入层单元、17 个隐藏层单元和 1 个输出层单元组成,并以学习效率为 0.1、动量因子为 0.5 和迭代次数为 300 对 BP 神经网络进行训练。




图 7 各模型预报结果对比

Fig.7 Comparison of forecast results of various models

由图 7 可见,LSTM-GM 神经网络模型的预报结果在数值与变化趋势上与监测结果最为接近,整体在监测值附近上下波动,而 LSTM 神经网络和 BP 神经网络的预报结果与监测值相比,虽然变化趋势整体一致,但预报误差相对较大,验证了 LSTM-GM 神经网络模型在处理时间序列问题上具有较大的优势,能够充分挖掘相隔较长时间风暴潮增水值之间的关联性,可有效处理风暴潮增水各影响因素间的非线性关系,提高风暴潮增水预报的精度。

各模型预报精度的评价结果如表 2 所示,可见 LSTM-GM 神经网络模型预报结果的各项评价指标都明显优于其他预报模型,不仅有效提高了风暴潮增水预报的整体精度,还显著提高了风暴潮最大增水值的预报精度。相对于 LSTM 和 BP 神经网络,利奇马台风影响期间,LSTM-GM 神经网络模型的 NSE 分别提高了 19.5% 和 11.4%;RMSE 分别降低了 82.5% 和 79.4%,MAPE 分别降低了 83.3% 和 79.2%, $\Delta y_p$  分别降低了 33.3% 和 75%;烟花台风影响期间,LSTM-GM 神经网络模型的 NSE 指标分别提高了 6.5% 和 11.4%;RMSE 分别降低了 70.6% 和 72.2%,MAPE 分别降低了 50% 和 69.2%, $\Delta y_p$  分别降低了 33.3% 和 71.5%。上述结果表明,本文提出的 LSTM-GM 神经网络模型具有良好的预报稳定性和泛化能力,可有效提高风暴潮

增水的预报精度。

表 2 各模型预报精度的评价结果

Table 2 Evaluation results of forecast accuracy of each model

| 台风  | 预报模型    | NSE  | RMSE/m | MAPE  | $\Delta y_p$ |
|-----|---------|------|--------|-------|--------------|
| 利奇马 | LSTM    | 0.82 | 0.20   | 0.15  | 0.03         |
|     | BP      | 0.88 | 0.17   | 0.12  | 0.08         |
|     | LSTM-GM | 0.98 | 0.035  | 0.025 | 0.02         |
| 烟花  | LSTM    | 0.92 | 0.17   | 0.08  | 0.03         |
|     | BP      | 0.88 | 0.18   | 0.13  | 0.07         |
|     | LSTM-GM | 0.98 | 0.05   | 0.04  | 0.02         |

3 结 语

本文选取台风因素、气象因素和天文潮因素中的 8 个风暴潮增水主要影响因素,结合 LSTM 神经网络和灰色模型的优势,提出一种基于 LSTM-GM 神经网络模型的风暴潮增水预报方法,对小清河入海口风暴潮增水监测数据进行拟合与预报,并与 LSTM 神经网络和 BP 神经网络预报结果进行对比。通过预报结果对比分析可知,LSTM-GM 神经网络模型预报结果的各项指标均优于 LSTM 神经网络和 BP 神经网络,其 MAPE 为 0.04,满足风暴潮增水预报精度要求。可见,提出的基于 LSTM-GM 神经网络模型的风暴潮增水预报方法具有良好的准确性和稳定性,为风暴潮增水预报提供了一种新的途径。

参考文献:

[ 1 ] 吴亚楠,王智峰,董胜,等. 山东沿海台风风暴潮数值模拟与统计分析[J]. 自然灾害学报,2015,24(3):169-176. (WU Ya'nan, WANG Zhifeng, DONG Sheng, et al. Numerical simulation and statistic analysis of typhoon storm surge in coastal area of Shandong Province [J]. Journal of Natural Disasters, 2015, 24(3):169-176. (in Chinese))

[ 2 ] 国家海洋局. 中国海洋灾害公报[R]. 北京:国家海洋局,2020.

[ 3 ] 罗志发,黄本胜,邱静,等. 粤港澳大湾区风暴潮时空分布特征及重点区域影响机理分析[J]. 水资源保护, 2022,38(3):72-79. (LUO Zhifa,HUANG Bensheng, QIU Jing, et al. Spatio-temporal distribution characteristics and influencing mechanisms of storm surge in Guangdong, Hong Kong and Macao Greater Bay Area [J]. Water Resources Protection, 2022, 38(3):72-79. (in Chinese))

[ 4 ] 尹姗姗,陈强. 珠海海域台风风暴潮经验预报方法研究[J]. 水利科技与经济,2015,21(11):84-86. (YIN Shanshan,CHEN Qiang. Statistical forecast of storm surge research on sea area of Zhuhai [J]. Water Conservancy Science and Technology and Economy,2015,21(11):84-86. (in Chinese))

[ 5 ] 苑希民,王亚东,田福昌. 溃漫堤洪水多维耦联数值模

- 型及应用[J]. 天津大学学报(自然科学与工程技术版), 2018, 51(7): 675-683. (YUAN Ximin, WANG Yadong, TIAN Fuchang. Application of multidimensional coupling numerical model for collapse flood[J]. Journal of Tianjin University (Science and Technology), 2018, 51(7): 675-683. (in Chinese))
- [6] 蒋昌波, 赵兵兵, 邓斌, 等. 北部湾台风风暴潮数值模拟及重点区域风险分析[J]. 海洋预报, 2017, 34(3): 32-40. (JIANG Changbo, ZHAO Bingbing, DENG Bin, et al. Numerical simulation of typhoon storm surge in the Beibu Gulf and hazardous analysis at key areas [J]. Marine Forecasts, 2017, 34(3): 32-40. (in Chinese))
- [7] 徐婉明, 邓伟铸, 赵明利, 等. 深圳 0814 号台风风暴潮数值模拟及最高潮位特征分析[J]. 海洋预报, 2020, 37(1): 11-17. (XU Wanming, DENG Weizhu, ZHAO Mingli, et al. Numerical simulation of the storm surge and characteristics of the highest tide level in Shenzhen caused by typhoon 0814 [J]. Marine Forecasts, 2020, 37(1): 11-17. (in Chinese))
- [8] WANG S, MU L, YAO Z, et al. Assessing and zoning of typhoon storm surge risk with a geographic information system (GIS) technique: a case study of the coastal area of Huizhou [J]. Natural Hazards and Earth System Sciences, 2021, 21(1): 439-462.
- [9] 苑希民, 李鸿雁, 刘树坤, 等. 神经网络和遗传算法在水科学领域的应用[M]. 北京: 中国水利水电出版, 2002.
- [10] YUAN X, ZHANG X, TIAN F. Research and application of an intelligent networking model for flood forecasting in the arid mountainous basins [J]. Journal of Flood Risk Management, 2020, 13(3): e12638.
- [11] 卢君峰, 李少伟, 袁方超. 基于 BP 神经网络的厦门沿海台风风暴潮预报应用[J]. 海洋预报, 2016, 33(4): 9-16. (LU Junfeng, LI Shaowei, YUAN Fangchao. Application of storm surge forecasting by BP artificial neural network off coast of Xiamen [J]. Marine Forecasts, 2016, 33(4): 9-16. (in Chinese))
- [12] 周寅杰, 刘强, 张晓琪. 基于 TSA-BP 模型的温州站台风风暴潮增水预测[J]. 海洋环境科学, 2022, 41: 807-812. (ZHOU Yinjie, LIU Qiang, ZHANG Xiaoqi. Prediction of typhoon storm surge at Wenzhou station based on TSA-BP model [J]. Marine Environmental Science, 2022, 41: 807-812. (in Chinese))
- [13] 刘媛媛, 张丽, 李磊, 等. 基于多变量 LSTM 神经网络模型的风暴潮临近预报[J]. 海洋通报, 2020, 39(6): 689-694. (LIU Yuanyuan, ZHANG Li, LI Lei, et al. Storm surge nowcasting based on multivariable LSTM neural network model [J]. Marine Science Bulletin, 2020, 39(6): 689-694. (in Chinese))
- [14] 刘媛媛, 刘业森, 张丽, 等. 基于神经网络模型对风暴潮特征分析及预测: 以深圳赤湾站和南澳站为例[J]. 中国防汛抗旱, 2022, 32: 66-71. (LIU Yuanyuan, LIU Yesen, ZHANG Li, et al. Characteristics analysis and tide level prediction of storm surge based on neural network model: taking Chiwan and Nan'ao in Shenzhen City as an example [J]. China Flood & Drought Management, 2022, 32: 66-71. (in Chinese))
- [15] TSENG C M, JAN C D, WANG J S, et al. Application of artificial neural networks in typhoon surge forecasting[J]. Pergamon, 2007, 34(11/12): 1757-1768.
- [16] SAHOO B, BHASKARAN P K. Prediction of storm surge and coastal inundation using artificial neural network: a case study for 1999 Odisha Super Cyclone [J]. Weather and Climate Extremes, 2019, 23: 100196.
- [17] KIM S, PAN S, MASE H. Artificial neural network-based storm surge forecast model: practical application to Sakai Minato, Japan [J]. Applied Ocean Research, 2019, 91: 101871.
- [18] 朱佩京, 罗年学, 赵前胜. 基于随机森林模型的台风风暴潮最大增水预测[J]. 测绘通报, 2021(12): 71-74. (ZHU Peijing, LUO Nianxue, ZHAO Qiansheng. Prediction of maximum water increase in typhoon storm surge based on random forest model [J]. Bulletin of Surveying and Mapping, 2021(12): 71-74. (in Chinese))
- [19] 姚伟. 基于机器学习的南海北部风暴增水预报研究[D]. 北京: 国家海洋环境预报中心, 2021.
- [20] 吕忻, 丁骏. 基于深度学习的潮位预报订正技术研究[J]. 海洋预报, 2022, 39(2): 70-79. (LYU Xin, DING Jun. Study on the correction technology of tide level forecast based on deep learning [J]. Marine Forecasts, 2022, 39(2): 70-79. (in Chinese))
- [21] 苗庆生, 徐珊珊, 杨锦坤, 等. 长短期记忆神经网络在厦门风暴潮预报中的应用[J]. 中国海洋大学学报(自然科学版), 2022, 52: 10-19. (MIAO Qingsheng, XU Shanshan, YANG Jinkun, et al. Application of long short-term memory neural network in Xiamen storm surge forecast [J]. Periodical of Ocean University of China 2022, 52: 10-19. (in Chinese))
- [22] 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: 290-295. (XUE Ming, LI Xingfei, CHENG Fanglin. Comparative analysis of storm surge water prediction methods based on multiple neural networks [J]. Marine Science Bulletin, 2019, 38: 290-295. (in Chinese))
- [23] 王亦斌, 孙涛, 梁雪春, 等. 基于 EMD-LSTM 模型的河流量水位预测[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))
- [24] 田烨, 谭伟丽, 王国庆, 等. 多种 LSTM 变体模型在径流预报中的应用及其可解释性[J]. 水资源保护, 2023, 39(3): 188-194. (TIAN Ye, TAN Weili, WANG Guoqing, et al. Application and interpretability of the LSTM models in runoff prediction [J]. Water Resources

- Protection, 2023, 39(3):188-194. (in Chinese))
- [25] 马景,武周虎,邹艳均,等. 基于灰色马尔科夫模型的南四湖水质预测[J]. 水资源保护, 2021, 37(5): 153-158. (MA Jing, WU Zhouhu, ZOU Yanjun, et al. Water quality prediction of Nansi Lake based on grey Markov model [J]. Water Resources Protection, 2021, 37(5): 153-158. (in Chinese))
- [26] 李浩飞,常伟纲,楚宪亮. 新信息优先的灰色模型在沉降预测中的应用[J]. 测绘地理信息, 2020, 45(6): 97-99. (LI Haoifei, CHANG Weigang, CHU Xianliang. Application of gray model with new information priority in settlement prediction [J]. Journal of Geomatics, 2020, 45(6): 97-99. (in Chinese))
- [27] 张朝飞,罗建军,徐兵华,等. 基于灰色理论的新陈代谢自适应多参数预测方法[J]. 上海交通大学学报, 2017, 51(8): 970-976. (ZHANG Zhaoifei, LUO Jianjun, XU Binghua, et al. Metabolism adaptive multi-parameter prediction method based on grey theory [J]. Journal of Shanghai Jiaotong University, 2017, 51(8): 970-976. (in Chinese))
- [28] 郝导华,马晓丽,张美. 小清河入海口现状及管理探索[J]. 山东水利, 2015(2): 22-23. (HAO Daohua, MA Xiaoli, ZHANG Mei. The current situation and management exploration of Xiaoqing River estuary [J]. Shandong Water Resources, 2015(2): 22-23. (in Chinese))
- [29] 邵利民,傅刚,曹祥村,等. BP 神经网络在台风路径预报中的应用[J]. 自然灾害学报, 2009, 18(6): 104-111. (SHAO Limin, FU Gang, CHAO Xiangcun, et al. Application of BP neural network to forecasting typhoon tracks [J]. Journal of Natural Disasters, 2009, 18(6): 104-111. (in Chinese))
- [30] 冯快乐,周建中,江焱生,等. 基于 BP 神经网络的湖北省山洪灾害危险性评价[J]. 自然灾害学报, 2018, 27(1): 148-154. (FENG Kuaile, ZHOU Jianzhong, JIANG Yansheng, et al. Assessment on the hazard of flash flood disaster in Hubei Province based on BP neural network [J]. Journal of Natural Disasters, 2018, 27(1): 148-154. (in Chinese))
- [31] 纪芳,侯一筠. 改进 BP 算法在风暴潮极值水位预报中的应用[J]. 中国海洋大学学报(自然科学版), 2011, 41(5): 120-123. (JI Fang, HOU Yijun. Application of improved BP neural network method in storm surges forecast [J]. Periodical of Ocean University of China, 2011, 41(5): 120-123. (in Chinese))
- [32] 朱新国,张展羽,祝卓. 基于改进型 BP 神经网络马尔科夫模型的区域需水量预测[J]. 水资源保护, 2010, 26(2): 28-31. (ZHU Xinguo, ZHANG Zhanyu, ZHU Zhuo. Prediction of water demand based on improved BP neural network and Markov model [J]. Water Resources Protection, 2010, 26(2): 28-31. (in Chinese))

(收稿日期:2022-10-11 编辑:王芳)

(上接第 7 页)

- [21] 石红旺,赵勇,屈吉鸿,等. 天津市城市居民用水行为调查及影响因素识别[J]. 水电能源科学, 2015(6): 143-147. (SHI Hongwang, ZHAO Yong, QU Jihong, et al. Behavior survey and influencing factors recognition of urban residential water in Tianjin City [J]. Water Resources and Power, 2015(6): 143-147. (in Chinese))
- [22] 王海叶,赵勇,李海红,等. 缺水型特大城市家庭水能关系分析与改进措施[J]. 水电能源科学, 2016(11): 44-48. (WANG Haiye, ZHAO Yong, LI Haihong, et al. , Analysis and improvement measures of water energy relationship of water shortage type super-urban families [J]. Water Resources and Power, 2016(11): 44-48. (in Chinese))
- [23] 孙才志,郝帅,赵良仕. 中国水资源-能源-粮食纽带系统效率时空分异特征[J]. 水资源保护, 2021, 37(1): 61-68. (SUN Caizhi, HAO Shuai, ZHAO Liangshi. Spatial-temporal differentiation characteristics of water resources-energy-food nexus system efficiency in China [J]. Water Resources Protection, 2021, 37(1): 61-68. (in Chinese))
- [24] 张光辉,费宇红,王茜,等. 灌溉农业的地下水保障能力评价方法研究-黄淮海平原为例[J]. 水利学报, 2016, 47(5): 608-615. (ZHANG Guanghui, FEI Hongyu, WANG Xi, et al. Evaluation methodology of groundwater safeguard capacity on agricultural irrigation in the Huang-Huai-Hai Plain [J]. Journal of Hydraulic Engineering, 2016, 47(5): 608-615. (in Chinese))
- [25] 牛庆静. 中国化石能源消费、碳排放与经济增长关系研究[D]. 济南:山东大学, 2015.
- [26] 曾萌,张园园,王红瑞,等. 中国水-能源纽带关系双向消耗核算研究[J]. 水资源保护, 2022, 38(5): 159-165. (ZENG Meng, ZHANG Yuanyuan, WANG Hongrui, et al. Bidirectional consumption accounting of water-energy nexus in China [J]. Water Resources Protection, 2022, 38(5): 159-165. (in Chinese))
- [27] 姜珊. 水-能源纽带关系解析与耦合模拟[D]. 北京:中国水利水电科学研究院, 2017.
- [28] 王庆明,张越,赵勇,等. 河北省井灌区灌溉用水与耗能变化规律研究[J]. 南水北调与水利科技(中英文), 2018(4): 154-159. (WANG Qingming, ZHANG Yue, ZHAO Yong, et al. Study on the change of irrigation water utilization and energy consumption in well irrigation areas of Hebei Province [J]. South-to-North Water Transfers and Water Science & Technology, 2018(4): 154-159. (in Chinese))
- [29] ZHAO Y, ZHU Y, LIN Z, et al. Energy reduction effect of the South-To-North Water Diversion Project in China [J]. Scientific Reports, 2017, 7(1): 15956.

(收稿日期:2022-10-17 编辑:王芳)