

DOI:10.3876/j.issn.1000-1980.2025.05.019

基于 LSTM 模型的宁波沿海风暴增水预报研究

陈永平^{1,2}, 王瑾琪^{1,2}, 徐晓武³, 丁 骏³, 谭 亚^{1,2}, 宗志锋⁴

(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. 浙江省海洋监测预报中心, 浙江 杭州 310007; 4. 上海市水旱灾害防御技术中心, 上海 200050)

摘要: 为提高宁波沿海风暴潮位预报的时效性与精度, 基于 LSTM 模型开展了风暴潮引起的增水智能预报研究。基于历史台风和虚拟台风信息, 利用 ADCIRC 水动力模型计算了台风期间宁波沿海潮位站的风暴增水, 构建了风暴增水样本数据库; 应用 LSTM 模型对宁波沿海风暴增水样本数据进行训练, 通过样本优化与参数调优, 建立了稳健高效的宁波沿海风暴增水智能预报模型。202212 台风“梅花”检验结果表明, 当训练样本超过 400 场时, 所构建的预报模型可以较好地实现宁波沿海风暴增水 1~12 h 的短期预报, 当预见期超过 12 h 后, 预报结果与实测数据将可能出现较大偏差。

关键词: 风暴增水; 虚拟台风; 智能预报; LSTM 模型; 宁波沿海

中图分类号: P731.23 文献标志码: A 文章编号: 1000-1980(2025)05-0162-08

Research on storm surge forecasting in coastal areas of Ningbo City based on LSTM model

CHEN Yongping^{1,2}, WANG Jinqi^{1,2}, XU Xiaowu³, DING Jun³, TAN Ya^{1,2}, ZONG Zhifeng⁴

(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. Zhejiang Marine Monitoring and Forecasting Center, Hangzhou 310007, China;
4. Shanghai Flood and Drought Disaster Prevention Technology Center, Shanghai 200050, China)

Abstract: To enhance the timeliness and accuracy of storm surge forecasting in the coastal areas of Ningbo City, an intelligent storm surge prediction system using a long short-term memory (LSTM) model was developed. Based on historical typhoon records and virtual typhoon information, storm surges at tidal stations along the coastal areas of Ningbo City during typhoon events were calculated with the ADCIRC hydrodynamic model, creating a storm surge sample database. The LSTM model was applied to train the sample data of storm surges in the coastal areas of Ningbo City, and a robust and efficient intelligent forecasting model for storm surges in the coastal areas of Ningbo City was established through sample optimization and parameter calibration. The test results of No. 202212 Typhoon Muifa show that when the number of trained samples exceeds 400, the constructed forecasting model can accurately achieve short-term (1-12 hours) forecasting of storm surges in the coastal area of Ningbo City. However, when the forecast period exceeds 12 hours, there may be significant deviations between the forecasting results and the actual data.

Key words: storm surge; virtual typhoon; intelligent forecasting; LSTM model; coastal area of Ningbo City

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^[1]。根据风暴的性质, 风暴潮通常可分为由台风引起的台风风暴潮和由温带气旋与冷空气引起的温带风暴潮两大类^[2]。我国是遭受风暴潮灾害影响最严重的国家之一, 因此开展风暴潮引起的增水(以下简称“风暴增水”)预报研究对我国海岸防灾减灾能力的提升具有重要意义。目前, 风暴增水预报方法主要分为经验统计预报、数值模型预报和人工智能预报 3 种^[3]。随着人工智能的发展, 以人工神经网络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, 在水文预报领域的优势凸显^[4-5]。

基金项目: 国家重点研发计划项目(2023YFC3008100); 浙江省基础公益研究计划项目(LGF22D060010); 宁波市水利科技计划项目(NSKA202538)

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: ypch@hhu.edu.cn

引用本文: 陈永平, 王瑾琪, 徐晓武, 等. 基于 LSTM 模型的宁波沿海风暴增水预报研究[J]. 河海大学学报(自然科学版), 2025, 53(5): 162-169.

CHEN Yongping, WANG Jinqi, XU Xiaowu, et al. Research on storm surge forecasting in coastal areas of Ningbo City based on LSTM model[J]. Journal of Hohai University(Natural Sciences), 2025, 53(5): 162-169.

目前,机器学习在风暴增水预报中的应用主要分为两类:①基于水动力模型的混合预报模式,其基本思想为采用机器学习模型对水动力模型的预报结果进行修正以得到更高精度的风暴增水预报结果。例如:Bajo 等^[6]以基于 SHYFEM 模型的风暴增水模拟结果作为输入层,通过人工神经网络学习模拟结果与实测值之间的非线性关系从而对模拟结果进行修正,成功建立了意大利威尼斯沿海风暴增水混合预报模型;French 等^[7]采用基于 TELEMAC 二维水动力模型和误差反向传播神经网络的混合模型对英国伊明赫姆港风暴增水进行了预报,模型模拟结果表明人工神经网络能够较好地修正水动力模型预报结果。②直接预报模式,即通过直接训练模型学习输入特征与风暴增水的非线性关系,再利用训练好的模型来预报风暴增水。直接预报模式根据输出数据长度可分为单步输出以及多步输出两类。例如:蔡煜东等^[8]基于早期的人工神经网络模型,以台风强度、中心风速及台风移速作为输入层,选取 50 场风暴增水数据作为模型训练样本,研究表明模型在测试集上的预报结果与实测值拟合良好;卢君峰等^[9]等基于 BP 人工神经网络建立了厦门沿海风暴增水预报模型,该模型以台风中心最大气压、最大风速、七级大风半径、台风中心距测站位置的距离和测站当地气压为输入层预报未来 1~6 h 的风暴增水,结果表明,3 h 以内的增水预报具有较高的精度;雷森等^[10]等基于循环神经网络模型,选取 31 场风暴增水数据为模型训练样本,结果表明 3 h 内风暴增水的预报结果与实测样本拟合较好,超过 3 h 的预报误差则显著增大。

本文基于历史台风和虚拟台风信息,利用 ADCIRC 水动力模型计算台风期间宁波沿海代表潮位站的风暴增水过程,构建风暴增水样本数据库;然后采用长短期记忆网络(long short-term memory, LSTM)模型对宁波沿海风暴增水预报值进行训练,通过样本优化和参数调优,构建了宁波沿海风暴增水智能预报模型,并以 202212 台风“梅花”为实例进行预报实践,分析了不同预见期和训练样本数目对模型预报精度的影响。

1 资料与方法

1.1 资料来源

a. 潮位资料。本文用于宁波沿海风暴潮模型验证的实测资料来源于宁波沿海的 5 个代表性潮位站(镇海、毛礁、湖头渡、强蛟和西泽),潮位数据的高程基面采用黄海基面,潮位站的具体分布如图 1 所示。

b. 台风资料。台风资料来自由中国气象局热带气旋资料中心发布的西北太平洋海域热带气旋最佳路径数据集^[11-12],该数据集记录了 1949 年以来西北太平洋地区热带气旋每 6 h 的位置和强度^[13]。

1.2 研究方法

a. ADCIRC 水动力模型。宁波沿海拥有漫长的海岸线和曲折的港湾,为了满足复杂岸线和高分辨率的要求,选择目前应用最广泛的 ADCIRC 水动力模型进行风暴潮数值模拟。ADCIRC 水动力模型在空间上采用有限单元法,在时间上采用有限差分法,网格采用非结构化三角形网格,该模型计算效率高并能够适应复杂的地形和水深条件。

b. LSTM 模型。基于深度学习的 LSTM 模型是一种循环神经网络模型(recurrent neural network, RNN)。LSTM 神经网络由多个重复单元组成,每个单元包含三个非线性门控结构:遗忘门、输入门和输出门,遗忘门决定从上一单元状态中丢弃哪些信息,输入门决定对单元状态添加哪些新的信息,最后输出门输出模型状态与模拟结果。LSTM 模型分为单步预报和多步预报两种模式。单步预报模型对历史数据的信息提取能力强,且预报精度通常较高;多步预报模型由于预报步长较多,不确定性因素的影响较大,精度一般略差于单步预报模型,但其实用性更强。本文分别构建了基于 LSTM 的单步(1 h 预报时长)和多步(3、6、12 h 预报时长)预报模型以适应不同的预报需求。

c. 前馈神经网络和支持向量机回归(support vector regression, SVR)。前馈神经网络是一种最简单的神经网络,各神经元分别属于不同的层,每一层的神经元可以接收前一神经元的信号,并产生信号输出至下一层,常见的前馈神经网络包括径向基函数神经网络(radial basis function neural network, RBFNN)和反向传播




图 1 宁波沿海潮位站分布

Fig. 1 Distribution of tidal stations along the coastal areas of Ningbo City

神经网络(back propagation neural network,BPNN)。支持向量机模型可用于处理分类以及回归问题,当用于处理回归问题时被称作 SVR,SVR 中一个关键概念即为支持向量,它是指提供非零拉格朗日乘数的训练向量,支持向量的数量代表了模型的复杂程度。

本文选取目前风暴潮智能预报中运用较为广泛的 BPNN 和 SVR 对风暴增水进行建模,并与 LSTM 模型进行性能对比。

2 样本数据集构建

2.1 风暴潮模型验证

为构建风暴增水样本数据集,需验证宁波沿海风暴潮模型(即 ADCIRC 水动力模型)的准确性,分别对其进行天文潮位和风暴增水模拟验证。

2.1.1 天文潮位验证

利用 ADCIRC 水动力模型对 2019 年 5 月 11—20 日的潮位过程进行模拟,结果如图 2 所示。可以看出,验证时间段内,各潮位站模拟结果与实测结果拟合良好,说明构建的水动力模型能够较好地模拟宁波沿海的天文潮过程。基于该水动力模型计算台风期间的天文潮过程,将实测潮位减去天文潮位,即可以计算得到沿海各潮位站台风期间的风暴增水过程。




图 2 宁波沿海天文潮位验证

Fig. 2 Astronomical tide level verification along the coastal areas of Ningbo City

2.1.2 风暴增水验证

选取 2019 年以来对宁波沿海产生明显风暴增水的 202106 号台风“烟花”作为验证案例。模型模拟计算时间为 2021 年 7 月 21 日 23 时至 2021 年 7 月 29 日 3 时,共计 172 h,每 1 h 输出一次潮位计算结果,风暴潮增水模拟值与实测值对比结果如图 3 所示。由图 3 可知,模拟值与实测值拟合较为良好,说明宁波沿海风暴潮模型能较好地模拟宁波沿海的风暴增水过程。

2.2 虚拟台风选取

开展风暴增水智能预报需要有足够的风暴增水数据训练样本,仅基于有限的历史台风信息不足以满足该要求,有必要构建更多的虚拟台风来充实训练样本数据集。参照徐晓武等^[14]的方法,采用模拟圆法筛选影响宁波沿海的台风,该方法以研究点为圆心,划定一定的半径,当一个台风路径与模拟圆相交或是位于模拟圆内时,即认定该台风对研究区域具有影响^[15-16]。Vickery 等^[17]通过参数化试验,建议模拟圆半径采用 250 km,当台风与研究区域距离小于 250 km 即认定该台风对研究区域具有影响。基于该筛选准则,分别从西北太平洋历史台风数据库和虚拟台风数据库中提取影响宁波沿海的台风,共筛选出影响宁波沿海的历史台风 89 场,虚拟台风 1 866 场。

2.3 风暴增水样本数据集构建

采用影响宁波沿海的历史台风与虚拟台风信息驱动宁波沿海风暴潮模型,模拟风暴增水值,并与台风的路径信息、中心最低气压、中心最大风速一起构建风暴增水样本数据集。

图 4 为各潮位站历史台风和虚拟台风风暴增水数据频率分布直方图,各潮位站历史台风和虚拟台风引




图 3 202106 号台风风暴增水验证

Fig. 3 Storm surge verification of No. 202106 typhoon




图 4 历史台风与虚拟台风风暴增水值频率分布

Fig. 4 Frequency distribution of storm surge values caused by historical typhoons and virtual typhoons

起的增水分布类似,大部分风暴增水值集中于 0~2.0 m 范围内;同时,虚拟台风在各潮位站引起的最大风暴增水值在 3.4~3.9 m 内,基本涵盖了台风所引起的风暴增水分布范围。综上所述,本文构建的风暴增水数据集具有代表性,符合实际台风增水规律,可为后续构建风暴增水智能预报模型提供良好的数据基础。

3 智能预报模型构建

本文应用 LSTM 模型对数据集进行训练以构建风暴增水智能预报模型,选取镇海、毛礁、湖头渡、强蛟和西泽作为代表潮位站以验证模型的精度和泛化能力。

3.1 数据集划分

对于机器学习模型,数据集通常包括训练集、验证集和测试集 3 种类型。本文选择风暴增水数据库中的 1 866 场虚拟台风对应的风暴增水数据作为模型的训练样本,其中 1 200 场用作训练集,666 场用作验证集,而 89 场历史台风对应的风暴增水数据作为模型的测试集。

从图 4 可以看出,训练集中的增水数据(即图 4 中的虚拟台风)分布与测试集的增水数据(即图 4 中的历史台风)分布基本相似。此外,训练集中的风暴增水模拟值的数据波动完全涵盖了测试集中的风暴增水模拟值的数据波动,这为训练完成后的模型在测试集中高精度地预报风暴增水提供了保障。

3.2 模型输入层与输出层

本文构建的机器学习模型的输出层为风暴增水值时序序列,故模型的输入特征应包含台风的路径信息,即台风中心经纬度、最低气压以及台风最大风速,模型输入特征还包含了台风期间各潮位站的气压与风速值。统计得到台风中心经纬度(用台风距潮位站距离替代)、台风中心最低气压、台风最大风速、潮位站气压、潮位站风速等输入特征值与风暴增水的相关系数分别为 0.3653、-0.3816、0.3990、-0.5488、0.7177,可见台风中心最低气压和潮位站气压与风暴增水负相关,台风中心经纬度、台风最大风速和潮位站风速与风暴增水正相关;从相关性程度来看,与台风行进相关的输入特征相关性略低于潮位站输入特征,其相关系数绝对值范围在 0.36~0.40 之间,潮位站风速与风暴增水相关性最强。为了使模型能够学习到风暴增水的时序特征,上述输入层特征均被选取为过去 12 h 的时序序列。

3.3 模型超参数调优

超参数是指模型在训练过程中无法自主学习修正的参数,且一经设定便在模型的整个训练过程中不再发生改变,模型的超参数调优是根据各参数的取值范围通过数值试验确定的,然而,对于每个超参数单步进行调优容易陷入局部最优而非全局最优的情况。为了避免这种情况,本文采用组合调优的方式确定超参数,即对各模型所有可能的超参数组合进行数值试验,并以验证集上的预报均方根误差(RMSE)为筛选标准,选取在验证集上 RMSE 最低的组合为最优超参数组合。各潮位站 LSTM 模型超参数调优的结果见表 1。

表 1 各潮位站 LSTM 模型的最优超参数组合
Table 1 Optimal hyperparameter combinations for LSTM model for each tidal station

潮位站	1 h 预见期	3 h 预见期	6 h 预见期	12 h 预见期
镇海	(128,16,0.1)	(128,16,0.2)	(256,32,0)	(128,16,0)
毛礁	(128,32,0)	(256,16,0.1)	(512,16,0.2)	(128,16,0)
湖头渡	(256,16,0.2)	(128,32,0.2)	(128,32,0)	(128,16,0)
强蛟	(128,16,0)	(128,16,0)	(128,16,0)	(128,16,0)
西泽	(256,16,0.1)	(256,32,0.2)	(256,16,0.2)	(128,16,0)

注:括号内的数据依次为隐藏层各层中 LSTM 神经元数、批尺寸和随机失活比。

4 实例验证

4.1 机器学习模型预报精度对比分析

基于测试集数据,可对训练得到的 LSTM、SVR 和 BPNN 模型进行预报精度测试。以 202212 号台风“梅花”为例,图 5 给出了在不同预见期下各机器学习模型镇海站风暴增水预报结果与宁波沿海风暴潮模型模拟的风暴增水值(即“目标值”)对比图。由图 5 可知,SVR 模型 1、3、6 h 预见期的预报结果都存在明显的波动,而 12 h 预见期预报结果数据波动更为明显,此时 SVR 模型的预报精度不符合要求;BPNN 模型 1、3、6 h 预见期预报结果均与目标值整体吻合,但当增水值大于 1 m 时,12 h 预见期预报结果低于目标值;LSTM 模型 1、3、6、12 h 预见期的预报结果皆与目标值吻合。




图 5 机器学习模型风暴增水预报结果与目标值对比

Fig. 5 Comparison of forecasting results of storm surges by machine learning models with target values

为进一步对比 3 个机器学习模型的性能,以镇海站为例统计不同预见期下 3 个模型在测试集上的相关系数和 RMSE 值。不同预见期下,SVR 模型相关系数最低且 RMSE 最高,而 LSTM 模型则是相关系数最高且 RMSE 最低, RMSE 范围为 0.03~0.14 m,且相关系数均大于 0.85。综上所述,LSTM 模型对风暴增水的预报精度优于 BPNN 模型和 SVR 模型,故本文将 LSTM 模型作为优选的风暴增水智能预报模型,在后续分析时着重讨论 LSTM 模型的模拟结果。

4.2 LSTM 模型不同预见期精度分析

以单步预报(1 h 预见期)为例,图 6 为 LSTM 模型在测试集上(89 场历史台风)的预报结果与其对应的目标值曲线,单步预报的 LSTM 模型的预报结果在 5 个潮位站上均与目标值吻合。图 7 进一步给出了不同预见期下 LSTM 模型在各潮位站上对风暴增水大于 10 cm 的预报误差(RMSE),可以看出随着预见期的增大,模型的预报误差也逐渐增大,就潮位站间的预报精度对比而言,强蛟站的预报精度略低于另 4 个潮位站。




图 6 LSTM 单步预报模型在测试集上的预报结果与目标值对比

Fig. 6 Comparison of forecasting results of LSTM single-step forecasting model on test sets with target values

风暴潮期间最为关注的是最大风暴增水值的预报结果,图 8 为不同预见期下 LSTM 模型对各历史台风最大风暴增水预报值与目标值的散点图。由图 8 可见,对 1、3、6 h 预见期,其散点图均位于或接近于 45°线,而 12 h 预见期各潮位站有较多散点偏离 45°线较远,最大风暴增水值的预报结果精度较差,且模型普遍低估了最大风暴增水值。这主要是因为随着预见期的增大,输入层与输出层的非线性关系变得更为复杂,导致 12 h 预见期的预报精度明显降低。

4.3 LSTM 模型数据量敏感性分析

相比少量的历史台风数据,本文选用了大量的虚拟台风数据支撑数据样本分析,这对于研究是否可以使用较少的台风数据量训练一个可靠的机器学习模型很有意义。Hashemi 等^[18]证明了在美国罗得岛沿海区域至少需要 200 场台风数据才能构建一个稳定的风暴增水预报模型,但考虑到宁波沿海的水动力条件有差异且所受台风影响的类型也不同,因此 Hashemi 的结论可能并不适用于宁波沿海。

为了检验数据集数量对模型性能的影响,以镇海站的单步预报为例评估了一个利用 100 场虚拟台风训练的风暴增水智能预报模型的性能。图 9 为该模型对测试集的预报值和目标值的散点图,大部分点都偏离最佳拟合线(45°线),模型预报结果普遍低于目标值。因此仅利用 100 场风暴增水样本无法训练出一个稳定高效的增水智能预报模型。

图 10 为镇海站不同数量虚拟台风数据集训练的模型对测试集的预报性能,可以看出,随着台风场次逐渐增加至 400 场,模型的 RMSE 逐渐降低,而当训练的场次继续增加时, RMSE 趋于稳定。对镇海站而言,构




图 7 不同预见期下 LSTM 模型风暴增水大于 10 cm 的预报误差

Fig. 7 Errors of LSTM model for forecasting storm surges exceeding 10 cm under different forecast periods




图 8 LSTM 模型最大风暴增水预报值与目标值散点图

Fig. 8 Scatter plots of forecast values of maximum storm surge by LSTM model against target values




图 9 100 场虚拟台风数据集训练的预报模型
预报值与目标值散点图




图 10 不同数量虚拟台风数据集训练下单步预报
模型的 RMSE 变化曲线

Fig. 9 Scatter plots of forecast values of forecasting model trained by 100 virtual typhoon datasets against target values Fig. 10 RMSE change curve of single-step forecasting model trained by different numbers of virtual typhoon datasets

建一个风暴增水单步预报模型至少需要 400 场风暴增水样本,而对于毛礁、湖头渡、强蛟和西泽站,这个数值分别为 300、350、300、400 场。因此对于宁波沿海而言,为构建一个高效的风暴增水智能预报模型至少需要 400 场风暴增水样本,而这远远超出了实际发生的台风数量,进一步证明了构建虚拟台风的必要性。

5 结 论

- a. BPNN、SVR、LSTM 3 个机器学习模型中,在 1~12 h 预见期下 SVR 模型的预报值与实测值的相关系数最低且 RMSE 最高,LSTM 模型的相关系数最高且 RMSE 最低,即 LSTM 模型的预报性能最佳,SVR 模型预报性能最差。
- b. LSTM 模型可以很好地实现对宁波沿海风暴增水的短期预报,但模型的预报精度随预见期的增大而降低,且最大风暴增水预报值较实测值明显偏小。
- c. 随着训练样本数量的增加,模型的预报精度逐渐提高,当台风场次达到 400 场后,模型的预报精度基本稳定。因此,为构建一个稳定高效的宁波沿海风暴增水智能预报模型,至少需要包含 400 场风暴增水样本,进一步证明了通过构建虚拟台风来扩充训练数据集的必要性。

参考文献:

[1] 金秋,周宏杰,陈永平. 宁波市沿海台风风暴潮增水数值预报研究[J]. 浙江水利科技,2018,46(6):22-25. (JIN Qiu,ZHOU Hongjie,CHEN Yongping. Prediction on storm surge water increase value of typhoons in coastal areas of Ningbo[J]. Zhejiang Hydrotechnics,2018,46(6):22-25. (in Chinese))

[2] 孙佳,左军成,黄琳,等. 东海沿岸台风及风暴潮灾害特征及成因[J]. 河海大学学报(自然科学版),2013,41(5):461-465. (SUN Jia,ZUO Juncheng,HUANG Lin,et al. Characteristics and causes of typhoon and storm surge along coast of East China Sea [J]. Journal of Hohai University (Natural Sciences),2013,41(5):461-465. (in Chinese))

[3] 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))

[4] 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,2022.

[5] 张文静,张振,黄剑,等. 基于图像语义分割的水位智能监测方法[J]. 河海大学学报(自然科学版),2023,51(5):24-30. (ZHANG Wenjing,ZHANG Zhen,HUANG Jian,et al. Intelligent water-level monitoring method based on image semantic segmentation[J]. Journal of Hohai University (Natural Sciences),2023,51(5):24-30. (in Chinese))

[6] BAJO M,UMGIESSER G. Storm surge forecast through a combination of dynamic and neural network models[J]. Ocean Modelling,2010,33(1/2):1-9.

[7] FRENCH J,MAWDSLEY R,FUJIYAMA T,et al. Combining machine learning with computational hydrodynamics for prediction of tidal surge inundation at estuarine ports[J]. Procedia IUTAM,2017,25:28-35.

[8] 蔡煜东,姚林声. 预报台风风暴潮极值的人工神经网络方法[J]. 海洋预报,1994,11(1):77-81. (CAI Yudong,YAO Linsheng. Artificial neural network method for typhoon storm surge prediction[J]. Marine Forecasts,1994,11(1):77-81. (in Chinese))

[9] 卢君峰,李少伟,袁方超. 基于 BP 神经网络的厦门沿海风暴潮预报应用[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))

[10] 雷森,史振威,石天阳,等. 基于递归神经网络的风暴潮增水预测[J]. 智能系统学报,2017,12(5):640-644. (LEI Sen,SHI Zhenwei,SHI Tianyang,et al. Prediction of storm surge based on recurrent neural network[J]. CAAI Transactions on Intelligent Systems,2017,12(5):640-644. (in Chinese))

[11] YING Ming,ZHANG Wei,YU Hui,et al. An overview of the China meteorological administration tropical cyclone database[J]. Journal of Atmospheric and Oceanic Technology,2014,31(2):287-301.

[12] LU Xiaoqin,YU Hui,YING Ming,et al. Western North Pacific tropical cyclone database created by the China meteorological administration[J]. Advances in Atmospheric Sciences,2021,38(4):690-699.

[13] 秦知朋,陈永平,潘毅,等. 基于 BO-LSTM 神经网络模型的台风浪波高预报方法研究[J]. 海洋学报,2024,46(10):107-116. (QIN Zhipeng,CHEN Yongping,PAN Yi,et al. Research on typhoon wave height prediction method based on BO-LSTM neural network model[J]. Haiyang Xuebao,2024,46(10):107-116. (in Chinese))

[14] 徐晓武,陈永平,谭亚,等. 基于核密度估计的经验路径模型在西北太平洋虚拟台风构建中的应用[J]. 海洋学报,2024,46(3):1-11. (XU Xiaowu,CHEN Yongping,TAN Ya,et al. Application of empirical path model based on kernel density estimation in the construction of synthetic typhoon in Northwest Pacific Ocean[J]. Haiyang Xuebao,2024,46(3):1-11. (in Chinese))

[15] VICKERY P J,TWISDALE L A. Prediction of hurricane wind speeds in the United States[J]. Journal of Structural Engineering,1995,121(11):1691-1699.

[16] GEORGIU P N. Design wind speeds in tropical cyclone-prone regions[D]. London,Ontario,Canada:Western University,1986.

[17] VICKERY P J,WADHERA D,TWISDALE JR L A,et al. U. S. hurricane wind speed risk and uncertainty[J]. Journal of Structural Engineering,2009,135(3):301-320.

[18] HASHEMI M R,SPAULDING M L,SHAW A,et al. An efficient artificial intelligence model for prediction of tropical storm surge[J]. Natural Hazards,2016,82(1):471-491.