

# 长短期记忆神经网络(LSTM)对风暴潮数值模拟的优化应用

陈鸿生<sup>1,2</sup>, 林小刚<sup>1,2\*</sup>, 林晓珍<sup>3</sup>

(1. 自然资源部海洋环境探测技术与应用重点实验室, 广东 广州 510301; 2. 国家海洋局汕尾海洋环境监测中心站, 广东 汕尾 516600; 3. 国家海洋局深圳海洋环境监测中心站, 广东 深圳 518000)

**摘要:** 利用长短期记忆神经网络和数值模式相结合的方法, 设计了两套针对粤东遮浪海洋站点台风风暴潮增水的预报优化方案。与实测资料对比结果显示, 长短期记忆神经网络方法可以显著改善数值模式模拟结果的准确性, 最大增水和主振过程中增水后报结果的平均绝对误差、平均相对误差和平均改善幅度分别为 7.1 cm、8.2%、74% 和 16.1 cm、34.7%、33%。进一步分析表明, 利用台风信息预测数值模拟结果的订正值可以有效改善神经网络方法的不稳定性, 比直接预测风暴潮增水值更加准确、可靠。

**关键词:** 长短期记忆; 神经网络; 台风风暴潮; 数值模拟

**中图分类号:** P731.23 **文献标识码:** A **文章编号:** 1003-0239(2024)04-0001-10

## 0 引言

风暴潮是影响我国沿海地区主要的海洋灾害, 也是导致该区域生命财产损失最严重的自然灾害之一。随着沿海地带建设的地下停车场和商场等越来越多, 一旦发生风暴潮灾害, 若没有及时准确的预报, 往往会造成人员伤亡。根据《中国海洋灾害公报》统计, 2013—2022 年我国有一半的年份(2014年、2015年、2017年、2018年、2021年)发生了因风暴潮灾害导致的人员死亡(含失踪)<sup>[1]</sup>。

台风风暴潮是指由热带气旋引起的海水异常升降现象。目前台风风暴潮主流的业务化预报方法是基于流体力学方程的数值模式预报, 但受限于台风风场预报误差、近岸复杂地形精确度等因素, 风暴潮数值预报精度很难进一步提高<sup>[2-3]</sup>。近年来日趋成熟的深度学习算法为这一问题的解决提供了新的方向。实际上, 深度学习在气象、海洋预报方面已经有许多研究和应用<sup>[4-7]</sup>, 最常用的方法是采用人工神经网络(Artificial Neural Network, ANN)进行学习训练。ANN以其无网格、自学习的特点被

引入到风暴潮预报应用中, 较早的研究大多采用前馈神经网络, 其中比较经典的算法为误差反馈(Back Propagation, BP)网络<sup>[8-15]</sup>。整体来看, BP神经网络的优势在于预报精度随预报时效的增长变化不大, 但误差水平难以调优。近几年一些研究针对BP神经网络进行了改进, 使得预报结果的准确度有了一定程度的改善<sup>[3, 16-17]</sup>。目前采用较多的方法为卷积神经网络(Convolutional Neural Network, CNN)和长短期记忆(Long Short-Term Memory, LSTM)神经网络<sup>[18-20]</sup>。CNN和LSTM作为当前主流的深度学习算法, 早在20世纪八九十年代就被提出<sup>[21-22]</sup>, 近几年随着算法的改进和计算机技术的进步, 被逐步应用到风暴潮预报中。在最新的相关研究中, WANG等<sup>[23]</sup>采用了更为复杂的CNN-LSTM神经网络, 苗庆生等<sup>[24]</sup>利用信息理论确定输入LSTM神经网络的10个影响因子, 均得到了较为准确的风暴潮预测结果。

目前利用单独的神经网络方法预测台风风暴潮时通常会将前一时刻的实况增水作为输入要素之一, 基于此来改进网络模型的短期(<12 h)预报效

收稿日期: 2023-09-04。

基金项目: 自然资源部海洋环境探测技术与应用重点实验室自主设立课题(MESTA-2022-D008)。

作者简介: 陈鸿生(1973-), 男, 工程师, 本科, 主要从事近岸海洋环境观测预报与生态监测工作。E-mail: 13502309288@189.cn

\*通信作者: 林小刚(1989-), 男, 工程师, 硕士, 主要从事近岸海洋环境预报工作。E-mail: l\_xiaogang@126.com

果,但是随着时效的增长,模型预报误差的增加十分显著,因此只能作临近预报<sup>[3,20,23-24]</sup>。而将神经网络与数值模拟结果相结合,可以在不将前一时刻实况增水作为输入要素的前提下,改善短期和较长时效预测结果的准确度,但在以往的此类研究中,预报结果的改善程度仍然有限<sup>[15,25]</sup>。另外,神经网络预测结果的不稳定性也是阻碍其应用的一个重要因素,其表现为对同一个台风多次训练再预测结果的不一致,以及对不同台风的预测误差变化较大。造成这一问题的主要原因之一是观测资料样本量偏少,因此一些研究采用理想化的台风风暴潮数值模拟结果作为深度学习的训练集合<sup>[11,16]</sup>,或者采用多次神经网络预测结果的平均值作为验证对象<sup>[23,26]</sup>,这些方法可以在一定程度上使神经网络的后报结果更加稳定。

基于上述问题,本文以粤东遮浪海洋站为例,利用LSTM神经网络和数值模式结果相结合的形式来改善风暴潮预测准确度,同时尝试利用不同的预测结果组合方案来克服观测样本较少所带来的稳

定性问题,并对最终结果的可靠性进行验证分析。

## 1 数据与方法

### 1.1 潮位资料和台风信息

潮位资料采用遮浪海洋站 20 年(2002—2021 年)的整点潮位数据。该站点为验潮井观测,具有良好的消波作用,能充分反映台风影响期间近岸水位变化。遮浪海洋站位置如图 1 所示。本文利用调和分析方法从实测潮位中分离出天文潮位,由此得到风暴潮增减水的量值。

台风信息来源于温州台风网(网址:<http://www.wztf121.com>)的历史台风数据查询,时间范围选取与潮位资料相对应(2002—2021 年)。获取的台风要素包含台风实时路径、台风中心气压、最大风速以及 7 级风圈半径。本文筛选相关台风的标准为最大增水值大于 30 cm、持续时间大于 3 h、在对应时间段内台风为影响研究海域的最主要天气系统。由此最终确定 16 个台风为研究对象,它们的路径及强度变化见图 1。

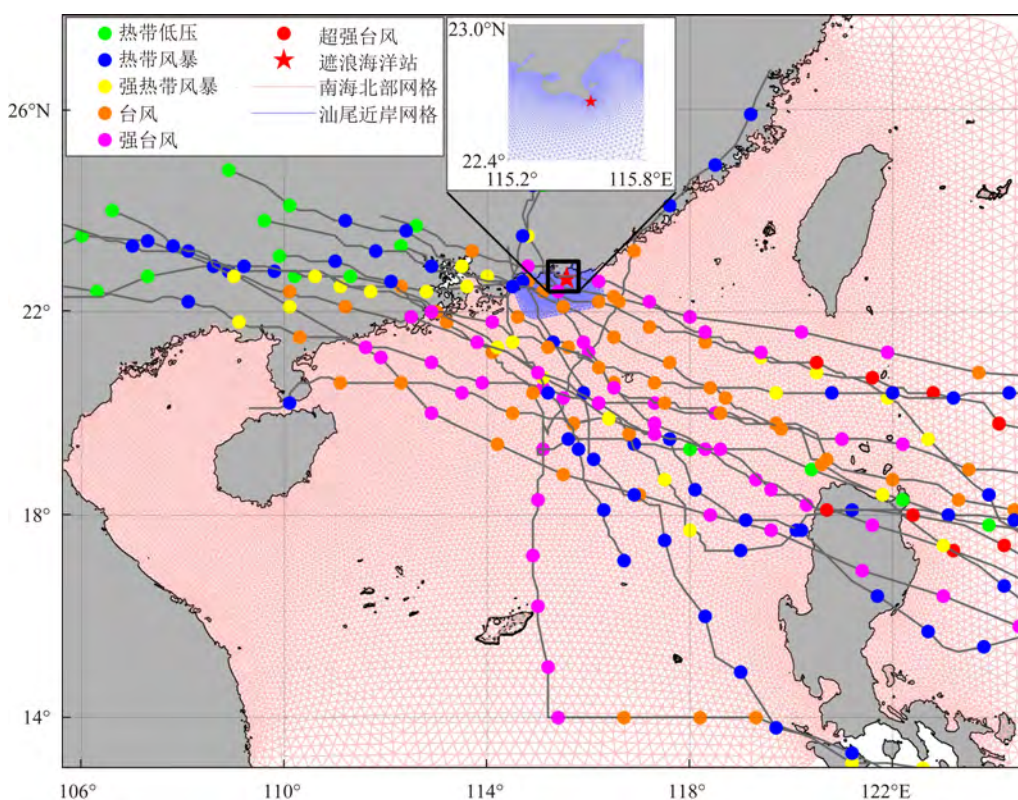


图1 数值模式网格、遮浪海洋站位置以及台风路径示意图

Fig.1 Numerical model grid, location of Zhelang marine station, and paths of typhoons



## 1.2 数值模式

本文采用的数值模式为有限体积海洋模式(Finite-Volume Community Ocean Model, FVCOM),它在近岸复杂地形的海洋动力过程模拟方面具有一定优势。经过多年发展,FVCOM已经集成多种物理、水质和生态模块,在海洋预报和海洋工程等领域有着广泛应用。有关该模式的更多细节可以参阅相关文献[27],这里不再赘述。本文的数值模式网格采用双层嵌套形式,外层为南海北部及周边海域,分辨率为10~30 km,内层为汕尾近岸海域,分辨率为500 m~10 km,垂向均为11层的sigma层。模式大气强迫场采用Holland台风模型风场和气压场[28],计算的时间步长为15 s。本文侧重于探讨神经网络对于数值模式结果的优化能力,数值模式的网格、地形及其他参数设置直接采用以往相对成熟的方案[29],但是不考虑潮汐、海浪等耦合过程,由此可以大幅减小计算量。

## 1.3 LSTM神经网络

LSTM是循环神经网络的一个优秀变种模型,在时间序列预测方面具有优异的表现[30]。LSTM的主要特点体现在其具有输入门、输出门和遗忘门结构,由此避免训练过程中的梯度消失或者梯度爆炸问题。本文设定的网络模型隐含层单位为100,初始学习率为0.01,每训练100次学习率降低为原来的0.8倍,训练次数为1 000次。由于隐含层单元数超过100以及训练次数超过1 000次后,模型的准确度提升很小,因此从提高训练效率角度考虑,分别将学习率和训练次数两个参数设定为100和1 000。所有输入模型的数据都先经过了归一化处理。

## 1.4 方案设计

我们将数值模式模拟的增水与台风信息一同输入神经网络,然后直接训练得到最终增水值,作为方案1,这种方案可以理解成“利用台风信息改善数值模式的模拟”。神经网络预测风暴潮是由输入因子组合到输出结果的“黑匣子”过程,这可能会导致输入信息利用率低下。如果方案1改善的程度没有超过数值模式原本模拟结果的准确度,那么这一“黑匣子”过程将为最终预测结果带来不可预知的

误差。因此我们设计了方案2,即神经网络的输入要素与方案1一致,但训练得到的并非最终增水值,而是数值模式模拟结果的订正值。在这种方式下,神经网络仅仅利用台风信息预测订正部分,数值模式的准确度会得到更大程度的保留,神经网络的“黑匣子”效应则会被限制在可控的范围内。为了充分检验这两种方案预测效果的差异,我们采用15:1的训练测试比,对全部16个台风样本都进行验证分析。具体方案流程及网络输入、输出要素见图2。

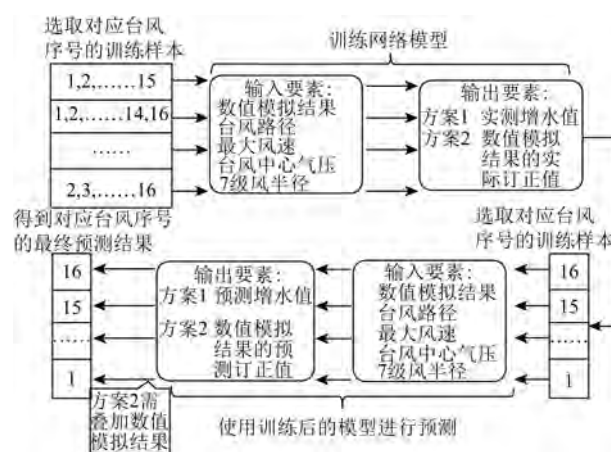


图2 两种神经网络预测方案的流程图

Fig.2 Flow charts of two schemes for neural network prediction models

由于本文设计的神经网络模型存在随机数的应用,并且用于训练的台风样本数量偏少,因此每次训练后得到的模型结果并不一致,这种情况在以往的研究中经常遇到[23,26]。为了充分检验神经网络模型的可靠性,我们对每个测试台风都进行了10次完整、独立的训练再预测,并将10次预测的变化区间作为对比结果。在进行误差分析时,最大增水取10次结果的最大值,主振过程取10次结果的平均值。需注意的是,本文采用的台风信息为实测数据,因此本文计算所得的结果均为后报结果。

## 2 结果分析与讨论

### 2.1 神经网络方案对数值模式的优化

数值模拟和两种神经网络方案预测的结果及误差对比见表1、2和图3。这其中,误差的计算仅针

表 1 数值模拟及两种神经网络方案最大增水预测的结果误差对比

Tab.1 Comparison of the predicted maximum storm surge error between numerical simulation and two neural network schemes

序号	测试台风编号 及名称	数值模式		方案 1			方案 2		
		MAE/cm	MRE/%	MAE/cm	MRE/%	增水改善 值/cm*	MAE/cm	MRE/%	增水改善 值/cm*
1	0307“伊布都”	43.6	62.9	1.8	2.6	41.8	10.8	15.6	32.8
2	0313“杜鹃”	30.0	35.0	0.6	0.7	29.4	0.8	0.9	29.2
3	0601“珍珠”	29.8	36.7	3.9	4.8	25.9	3.7	4.6	26.1
4	0812“鹦鹉”	38.2	39.8	0	0	38.2	1.3	1.3	36.9
5	0814“黑格比”	21.5	25.6	4.0	4.8	17.5	1.5	1.8	20.0
6	0904“浪卡”	1.4	4.1	3.5	10.7	-2.2	0.9	2.8	0.4
7	0906“莫拉菲”	29.2	48.1	1.1	1.8	28.1	1.1	1.9	28.0
8	1208“韦森特”	25.7	44.2	5.5	9.4	20.3	4.9	8.5	20.8
9	1319“天兔”	46.5	30.3	44.3	28.9	2.1	34.6	22.5	11.9
10	1604“妮姐”	7.0	10.3	1.7	2.5	5.2	5.3	7.8	1.7
11	1622“海马”	22.1	22.4	9.9	10.1	12.2	4.3	4.4	17.8
12	1702“苗柏”	16.4	43.7	6.8	18.2	9.6	10.1	27.0	6.3
13	1713“天鸽”	20.7	31.8	0.9	1.3	19.8	0.4	0.7	20.2
14	1714“帕卡”	13.9	33.8	1.0	2.5	12.9	2.1	5.2	11.8
15	1720“卡努”	41.1	59.1	0.9	1.3	40.2	5.3	7.6	35.8
16	1822“山竹”	54.0	38.1	42.8	30.2	11.2	26.1	18.4	27.9
平均		27.6	35.4	8.1	8.1	19.5	7.1	8.2	20.5

\* “增水改善值”指最大增水预测结果相对数值模式的改善值

对实际增水大于 30 cm 的时刻,以此避免因样本时间段选取的主观性对统计结果产生的影响。从表 1、2 中可以看到,数值模拟的最大增水和主振过程中增水的平均绝对误差(Mean Absolute Error, MAE)和平均相对误差(Mean Relative Error, MRE)分别为 27.6 cm、35.4% 和 24 cm、48.5%。两者的 MRE 结果显示,数值模式对主振过程中增水的模拟准确度比对最大增水的模拟差许多,前者的误差主要受台风模型准确度、模式网格分辨率、岸线地形精度以及是否考虑浪流耦合等因素影响<sup>[29]</sup>。

总体来看,神经网络对数值模拟结果的改善较为显著,并且方案 2 的结果优于方案 1。方案 2 中所有台风样本最大增水和主振过程中增水预测结果的 MAE 和 MRE 分别为 7.1 cm、8.2% 和 16.1 cm、34.7%,相比数值模式的误差减小了 20.5 cm、27.2%

和 7.9 cm、13.8%,效果较为理想。以 16 个台风的平均 MAE 为准进行计算,神经网络的预报改善幅度分别达到了 74% 和 33%。从最大增水预测结果来看,方案 2 相对数值模式的改善基本都在 20 cm 以上,而方案 1 的结果则参差不齐,甚至在数值模式结果较准确、改善空间有限的情况下出现了轻微的负优化。同样,方案 1 的主振过程中增水预测也出现了一次较严重的负优化,相比之下方案 2 对应结果的偏差较小。

从表 1、2 还可以看出,最大增水的误差变化范围较大,而主振过程中增水的误差相对稳定,更能反映统计特征。因此,我们绘制了神经网络和数值模式主振过程中增水 MAE 的散点图(见图 4),以进一步分析方案 1、2 预测结果的改善情况。从图 4 中可以看出,除了方案 1 的 1 个台风样本的误差较大

表2 数值模拟及两种神经网络方案主振过程中增水预测的结果误差对比

Tab.2 Comparison of the predicted main oscillation process error between numerical simulation and two neural network schemes

序号	测试台风编号 及名称	数值模式		方案1			方案2		
		MAE/cm	MRE/%	MAE/cm	MRE/%	增水改善 值/cm*	MAE/cm	MRE/%	增水改善 值/cm*
1	0307“伊布都”	26.1	53.9	21.1	45.6	5.0	22.6	48.6	3.4
2	0313“杜鹃”	26.8	54.4	19.6	40.4	7.3	16.2	34.2	10.6
3	0601“珍珠”	36.1	77.4	17.8	37.5	18.3	13.2	29.2	22.9
4	0812“鹦鹉”	14.5	26.1	11.1	23.1	3.4	12.9	28.1	1.6
5	0814“黑格比”	20.9	33.9	10.4	18.4	10.5	10.1	18.6	10.8
6	0904“浪卡”	16.8	54.0	11.7	37.3	5.1	16.3	52.7	0.5
7	0906“莫拉菲”	32.7	74.3	16.1	34.2	16.6	16.0	34.3	16.7
8	1208“韦森特”	23.6	53.1	18.5	41.4	5.1	17.9	40.3	5.6
9	1319“天兔”	33.5	58.8	30.8	54.7	2.7	23.1	39.0	10.5
10	1604“妮妲”	25.6	45.0	16.9	31.2	8.7	17.0	31.2	8.6
11	1622“海马”	23.5	34.8	18.2	31.8	5.3	14.4	24.3	9.1
12	1702“苗柏”	16.8	48.5	24.1	72.8	-7.4	17.0	50.3	-0.3
13	1713“天鸽”	12.2	24.9	10.6	25.6	1.6	10.9	26.7	1.3
14	1714“帕卡”	13.7	38.0	14.2	39.5	-0.6	12.2	33.4	1.5
15	1720“卡努”	33.2	60.7	20.0	38.1	13.3	19.7	38.1	13.5
16	1822“山竹”	28.3	37.6	20.3	26.7	8.0	18.4	25.6	9.9
平均		24.0	48.5	17.6	37.4	6.4	16.1	34.7	7.9

\*“增水改善值”指主振过程中增水预测结果相对数值模式的改善值

以外,神经网络对数值模式结果基本为正向优化作用;从离散点的二次拟合曲线可以看出,当数值模拟结果较准确时,神经网络的优化效果较弱;随着数值模拟的误差增大,神经网络的优化效果增强,误差水平趋于稳定,且方案2比方案1的优化作用更大。另外,从图4还可以看到,神经网络预测结果的MAE相对于拟合曲线的离散程度较大,说明这两种方案预测台风风暴潮增水的效果存在一定波动,这可能是样本数量偏少导致的。

## 2.2 神经网络的稳定性对比

从图3中可以明显看出,方案2预测结果的波动范围比方案1小得多,特别是对0601号台风“珍珠”和1319号台风“天兔”的模拟。实际上数值模式对这两个台风的最大增水模拟并不是最差,但是对

主振过程中增水的模拟误差最大。方案1的预测区间也存在同样问题,甚至进一步放大了过程预测的偏差。令人惊讶的是,方案2的结果并没有出现类似波动,而是在数值模拟结果的基础上进行了有限的修正,使得对最大增水和主振过程中增水的预测都表现为正优化。从移动路径上看,这两个台风是所有样本中仅有的两次从台风移动方向左侧影响观测站点并造成显著增水的过程,属于特殊情况,这可能是导致方案1预测结果波动较大的主要原因。这里应注意的是,图3中方案1、2的预测区间是指10次结果的整体范围,并不代表每次预测在这一范围内的出现概率一致,通常是偏差越大的预测出现的概率越小,这在图3中并没有体现。

为了进一步分析两种神经网络优化能力的稳定性,我们绘制了16个台风10次独立预测结果



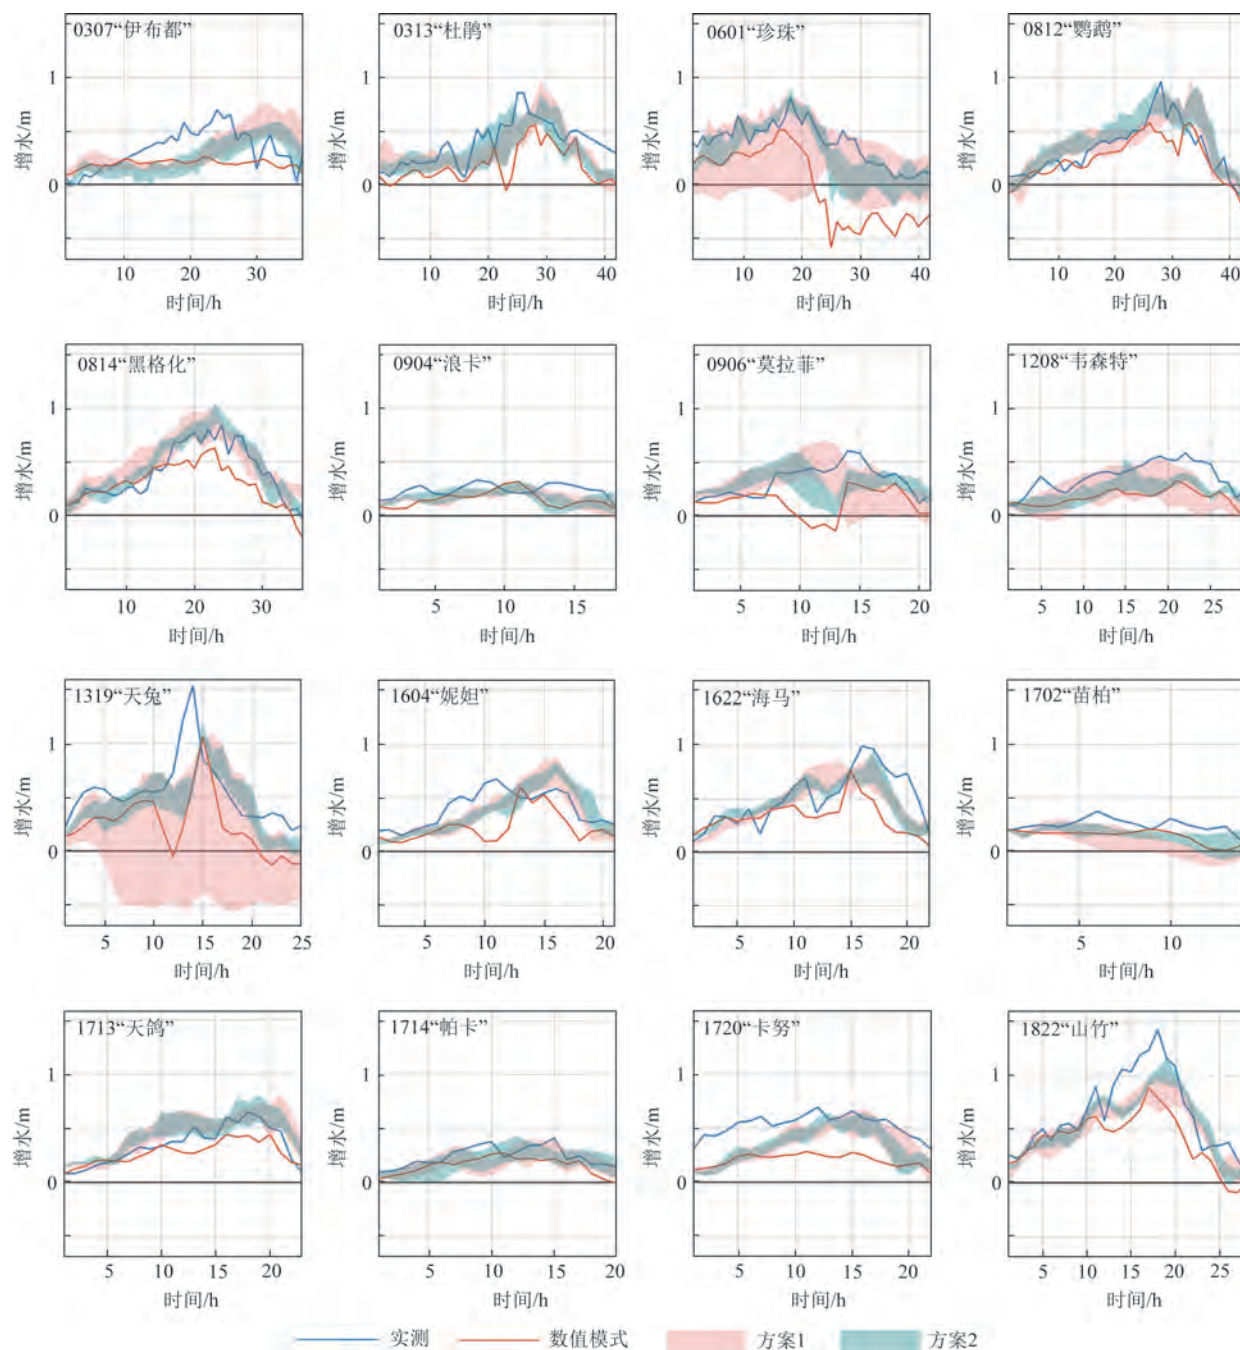


图3 数值模拟和两种神经网络方案预测的结果与风暴潮实况增水的对比

Fig.3 Comparison between the measured storm surge and the predicted results of numerical model and two neural network schemes

MAE的标准差变化(见图5),以此来对比其波动情况。从图5可以看出,无论是对于主振过程中增水的预测还是对于最大增水的预测,方案1的MAE标准差基本都大于方案2,并且0601号台风“珍珠”和1319号台风“天兔”的对应值异常偏大,这与图3中方案1的预测结果区间较大相一致。相比

之下,方案2的预测结果更稳定,甚至对主振过程中增水预测的MAE标准差全部小于5 cm。经过试验,如果将多次训练再预测的结果进行平均来保证神经网络方法的稳定性,那么方案1需要10次以上的预测才能达到方案2单次预测的稳定效果。




图4 主振过程中增水MAE的散点图及拟合曲线

Fig.4 Scatter plot and fitting curve of MAE in the main oscillation process




图5 两种神经网络方案多次预测结果MAE的标准差变化

Fig.5 The standard deviations of MAE from multiple predictions using two neural network schemes

### 2.3 对伪随机偏差的订正试验

由于数值模拟结果的准确度对于不同台风、不同观测站点存在较大差异,本文对16个台风样本的分析难以覆盖大多数情况。为了验证上述神经网络方案的适用性,我们设计了一个针对伪随机偏差的训练试验。首先,将数值模式模拟的风暴潮增水结果替换为:

$$S_{t,i} = S0_t - R_t \times i, i = 1:30 \quad (1)$$

式中: $S_{t,i}$ 为第*i*组*t*时刻的模拟增水值; $S0_t$ 为*t*时刻的实况增水值; $R$ 为在区间(0,2)内均匀分布的随机数向量,其长度与 $S0$ 一致,平均值为1; $R_t$ 表示*t*时刻对应的*R*向量的值。由式(1)可以得到30组试验增水,而它们的MAE(即 $R_t$ 的平均值)从1~30 cm均匀变化。将本文两种神经网络方法输入的数值模拟结果替换为试验增水*S*进行训练,可以得到台风样本预测结果MAE随伪随机偏差平均值的变化(见图6)。同样,我们针对每个台风及每组试验增水*S*进行10次完整、独立的训练再预测,而后分析其平均MAE。在这一试验中,将台风所有时刻的预测值都纳入误差统计分析当中。

从图6可以看出,两种神经网络方案预测结果的MAE随叠加的偏差平均值的变化趋势与图4的二次拟合曲线类似。当偏差平均值较小时,方案2的预测结果与订正偏差平均值的结果基本一致,而




图6 16个台风样本预测结果MAE随伪随机偏差平均值的变化

Fig.6 The average pseudo random deviation values of MAE in the prediction results of 16 typhoons

方案1的结果则较差。由于这里的偏差是基于平均分布的随机数,除了平均值以外,各时刻的波动是无法预测的,因此当这一偏差较实况增水的波动偏小时,相当于信号噪声较大,神经网络从中剔除平均值的难度就比较大。而此时方案2神经网络输出的预测订正值同样波动较小,有利于偏差平均值的确定,故其预测结果优于方案1。随着偏差平均值的逐渐增大,方案2和方案1的预测相继优于订正

偏差平均值的结果,并且优势不断增大,这充分体现了神经网络的自学习特性,可以从复杂变化中找出最优解。整体来看,方案2的平均误差水平比方案1小1.48 cm,同表2中两者主振过程中增水MAE的平均表现相一致。与这一结论类似,在该试验中,方案2多次预测结果MAE的波动情况较方案1小,并且针对各个台风样本的预测都很稳定(见图7)。通过上述试验对比可以进一步验证神经网络方法对于改善数值模式模拟结果的可行性,并且方案2的预测结果不论在准确性还是稳定性方面,都要优于方案1。




图7 伪随机偏差试验中神经网络方案多次预测结果MAE的标准差变化

Fig.7 The standard deviations of MAE from multiple predictions using neural network schemes in pseudo random deviation trials

### 3 结论

本文采用LSTM神经网络的方法,设计了直接预测增水值和预测订正值两种方案,以近20年对粤东遮浪海洋站点区域造成较显著风暴潮增水的16个台风样本为例,利用台风信息对数值模拟结果进行优化,并对两种方案预测结果的可靠性进行分析。结果表明:

①LSTM神经网络方法对数值模拟结果的改善显著,最大增水和主振过程中增水预测结果的MAE和MRE分别为7.1 cm、8.2%和16.1 cm、34.7%,较数值模式的误差减小了20.5 cm、27.2%和7.9 cm、

13.8%,改善幅度分别达到74%和33%。

②相较采用神经网络方法直接预测增水,利用其对数值模拟结果的订正值进行预测能够限制神经网络训练所带来的不确定性,更好地保留数值模式结果原本的准确度,使得最终的预测结果更加稳定、可靠。

风暴潮的预报误差很大程度上来源于对台风预测的偏差,较长时效的风暴潮预报必然要随着台风预测的更新而不断调整,这种情况下精细化数值预报难以发挥其优势;另外,神经网络方法需要利用大量数据进行训练才能得到理想的结果<sup>[30]</sup>,但是目前单个观测点中风暴潮增水较显著的台风样本一般仅有十几到几十个,难以满足要求。实际上,如果仅利用台风信息来训练神经网络,那么本文两个方案预测结果的最大增水MAE都大于25 cm,效果较差。而利用神经网络方法优化数值模式模拟结果,不但可以提高预测的准确性,还能灵活高效地设置集合预报方案,可操作性更强。特别是利用神经网络对数值结果的订正值进行预测,即使在数值模拟较准确的情况下,也几乎不会产生负优化,具有更好的可靠性。

### 参考文献:

- [1] 自然资源部. 2013—2022年中国海洋灾害公报[R]. 北京, 2013—2022.  
Ministry of Natural Resources. Bulletin of China marine disaster from 2013 to 2022[R]. Beijing, 2013-2022.
- [2] 刘秋兴, 董剑希, 于福江, 等. 覆盖中国沿海地区的精细化台风风暴潮模型的研究及适用[J]. 海洋学报, 2014, 36(11): 30-37.  
LIU Q X, DONG J X, YU F J, et al. A high-resolution typhoon storm surge forecast model covering the whole China's coastal areas and its application[J]. Acta Oceanologica Sinica, 2014, 36(11): 30-37.
- [3] CHAO W T, YOUNG C C, HSU T W, et al. Long-lead-time prediction of storm surge using artificial neural networks and effective typhoon parameters: revisit and deeper insight[J]. Water, 2020, 12(9): 2394.
- [4] HAQUE A U, MANDAL P, MENG J L, et al. Wind speed forecast model for wind farm based on a hybrid machine learning algorithm [J]. International Journal of Sustainable Energy, 2015, 34(1): 38-51.
- [5] KUMAR N K, SAVITHA R, AL MAMUN A. Regional ocean wave height prediction using sequential learning neural networks [J]. Ocean Engineering, 2017, 129: 605-612.
- [6] 周水华, 洪晓, 梁昌霞, 等. 基于人工神经网络的台风浪高快速计算方法[J]. 热带海洋学报, 2020, 39(4): 25-33.



- ZHOU S H, HONG X, LIANG C X, et al. A method of tropical cyclone wave height calculation based on Artificial neural network [J]. *Journal of Tropical Oceanography*, 2020, 39(4): 25-33.
- [7] ZHENG G, LI X F, ZHANG R H, et al. Purely satellite data-driven deep learning forecast of complicated tropical instability waves[J]. *Science Advances*, 2020, 6(29): eaba1482.
- [8] 薛彦广, 沙文钰, 徐海斌, 等. 人工神经网络在风暴潮增水预报中的应用[J]. *海洋预报*, 2005, 22(2): 33-37.
- XUE Y G, SHA W Y, XU H B, et al. Application of the artificial neural network in storm surge forecast[J]. *Marine Forecasts*, 2005, 22(2): 33-37.
- [9] LEE T L. Back-propagation neural network for the prediction of the short-term storm surge in Taichung harbor, Taiwan[J]. *Engineering Applications of Artificial Intelligence*, 2008, 21(1): 63-72.
- [10] CHEN W B, LIU W C, HSU M H. Predicting typhoon-induced storm surge tide with a two-dimensional hydrodynamic model and artificial neural network model[J]. *Natural Hazards and Earth System Sciences*, 2012, 12(12): 3799-3809.
- [11] KIM S, MATSUMI Y, MASE H, et al. Development of real time storm surge forecasting using artificial neural network[C]// *Proceedings of the 11th International Conference on Hydrosience & Engineering*. 2014.
- [12] KIM S W, MELBY J A, NADAL-CARABALLO N C, et al. A time-dependent surrogate model for storm surge prediction based on an artificial neural network using high-fidelity synthetic hurricane modeling[J]. *Natural Hazards*, 2015, 76(1): 565-585.
- [13] KIM S, MATSUMI Y, PAN S Q, et al. A real-time forecast model using artificial neural network for after-runner storm surges on the Tottori coast, Japan[J]. *Ocean Engineering*, 2016, 122: 44-53.
- [14] 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 J F, LI S W, YUAN F C. Application of storm surge forecasting by BP artificial neural network off coast of Xiamen [J]. *Marine Forecasts*, 2016, 33(4): 9-16.
- [15] 张娟, 周水华, 黄宝霞, 等. 人工神经网络在台风风暴潮模拟中的解释应用[J]. *海洋预报*, 2016, 33(2): 60-65.
- ZHANG J, ZHOU S H, HUANG B X, et al. Interpretation of numerical storm surge model results using the artificial neural network[J]. *Marine Forecasts*, 2016, 33(2): 60-65.
- [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] 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(5): 807-812.
- ZHOU Y J, LIU Q, ZHANG X Q. Prediction of typhoon storm surge at Wenzhou station based on TSA-BP model[J]. *Marine Environmental Science*, 2022, 41(5): 807-812.
- [18] 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 S, SHI Z W, SHI T Y, et al. Prediction of storm surge based on recurrent neural network[J]. *CAAI Transactions on Intelligent Systems*, 2017, 12(5): 640-644.
- [19] 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.
- XUE M, LI X F, CHENG F L. Comparative analysis of storm surge water prediction methods based on multiple neural networks [J]. *Marine Science Bulletin*, 2019, 38(3): 290-295.
- [20] 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 Y Y, ZHANG L, LI L, et al. Storm surge nowcasting based on multivariable LSTM neural network model[J]. *Marine Science Bulletin*, 2020, 39(6): 689-694.
- [21] WAIBEL A, HANAZAWA T, HINTON G, et al. Phoneme recognition using time-delay neural networks[J]. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1989, 37(3): 328-339.
- [22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [23] WANG B, LIU S C, WANG B, et al. Multi-step ahead short-term predictions of storm surge level using CNN and LSTM network [J]. *Acta Oceanologica Sinica*, 2021, 40(11): 104-118.
- [24] 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*, 2022, 52(9): 10-19.
- MIAO Q S, XU S S, YANG J K, et al. Application of long short-term memory neural network in Xiamen storm surge forecast[J]. *Periodical of Ocean University of China*, 2022, 52(9): 10-19.
- [25] 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.
- [26] WANG Q, CHEN J H, HU K L. Storm surge prediction for Louisiana coast using artificial neural networks[C]// *Proceedings of the 23rd International Conference on Neural Information Processing*. Kyoto: Springer, 2016: 396-405.
- [27] CHEN C S, BEARDSLEY R C, COWLES G, et al. An unstructured grid, finite-volume community ocean model: FVCOM user manual[R]. 2013.
- [28] 张余得, 商少平, 谢燕双, 等. 基于强风圈半径的台风风场模型[J]. *厦门大学学报(自然科学版)*, 2014, 53(2): 252-256.
- ZHANG Y D, SHANG S P, XIE Y S, et al. Typhoon wind field model based on the radii of wind circle[J]. *Journal of Xiamen University (Natural Science)*, 2014, 53(2): 252-256.
- [29] 林小刚, 罗荣真, 张娟, 等. 浪流耦合对汕尾港台风风暴潮模拟的影响[J]. *海洋预报*, 2020, 37(4): 30-37.
- LIN X G, LUO R Z, ZHANG J, et al. Effects of wave-current interaction on storm surge simulation in Shanwei Port[J]. *Marine Forecasts*, 2020, 37(4): 30-37.
- [30] KAREVAN Z, SUYKENS J A K. Transductive LSTM for time-series prediction: an application to weather forecasting[J]. *Neural Networks*, 2020, 125: 1-9.

## Application of Long Short-Term Memory neural network for optimization of numerical simulation results of storm surge

CHEN Hongsheng<sup>1,2</sup>, LIN Xiaogang<sup>1,2\*</sup>, LIN Xiaozhen<sup>3</sup>

(1. Key Laboratory of Marine Environmental Survey Technology and Application, Ministry of Natural Resources, Guangzhou 510301, China; 2. Shanwei Marine Environmental Monitoring Center, State Oceanic Administration, Shanwei 516600, China; 3. Shenzhen Marine Environmental Monitoring Center, State Oceanic Administration, Shenzhen 518000, China)

**Abstract:** Using a combination of Long Short-Term Memory (LSTM) neural network and numerical model, two sets of prediction schemes for typhoon storm surge at the Zhelang marine station in eastern Guangdong have been designed. Compared with the measured data, the LSTM neural network can significantly improve the accuracy of the numerical model results. The average absolute error, average relative error and average improvement amplitude of the prediction results for the maximum surge and the main oscillation process are 7.1 cm, 8.2%, 74% and 16.1 cm, 34.7%, 33%, respectively. Further analysis shows that predicting the corrected value of numerical results using typhoon information can effectively limit the instability of neural network, which is more accurate and reliable in comparison with predicting the storm surge level directly.

**Key words:** Long Short-Term Memory; neural network; typhoon storm surge; numerical simulation