

Doi: 10.11840/j.issn.1001-6392.2020.06.006

基于多变量 LSTM 神经网络模型的风暴潮临近预报

刘媛媛¹, 张丽², 李磊³, 刘业森¹, 陈柏纬⁴, 张文海⁵

(1. 中国水利水电科学研究院, 北京 100038; 2. 深圳市国家气候观测台 广东 深圳 519082; 3. 中山大学大气科学学院, 广东 珠海 519082; 4. 香港天文台, 香港 九龙 999077; 5. 深圳市强风暴研究院, 广东 深圳 518057)

摘 要: 台风的风暴潮是台风引发的一种重要次生灾害, 对沿海城市带来的威胁是多方面的。及时准确地预报风暴潮, 对沿海地区采取合理措施减少人员伤亡和经济损失具有重要意义。本文利用长短期记忆神经网络 (LSTM) 模型, 综合考虑风速、风向、气压等气象因素和前时序的潮位数据, 建立了风暴潮的临近预报模型。结果表明, 基于 LSTM 的临近预报模型具有相当的预报技巧, 利用前时序的风速和风向数据以及潮位数据建立的模型可对风暴潮潮位进行准确地预测。研究还表明, 仅考虑前时序潮位的预测模型误差最大, 考虑气压后的模型预测能力有一定进步, 而考虑风的要素以后, 预测的效果提升更为明显。

关键词: LSTM 神经网络模型; 热带气旋; 风暴潮; 临近预报

中图分类号: P731.34

文献标识码: A

文章编号: 1001-632(2020)06-0689-06

Storm surge nowcasting based on multivariable LSTM neural network model

LIU Yuanyuan¹, ZHANG Li², LI Lei³, LIU Yesen¹, CHAN Pakwai⁴, ZHANG Wenhai⁵

(1. China Institute of Water Resources and Hydropower Research, Beijing 100038, China; 2. Shenzhen National Climate Observatory, Shenzhen 518040, China; 3. School of Atmospheric Sciences, Sun Yat-Sen University, Zhuhai, 519082, China; 4. Hong Kong Observatory, Hong Kong 999077, China; 5. Shenzhen Academy of Severe Storms Science, Shenzhen 518057, China)

Abstract: A storm surge is an important secondary disaster caused by typhoons, and its threat to coastal cities is manifold. It is of great significance to forecast storm surges timely and accurately, and to adopt reasonable measures to reduce casualties and economic losses in coastal areas. This paper proposes a new algorithm which comprehensively considers wind speed, wind direction, atmospheric pressure, and other factors, as well as the tidal level observation data of preceding time series, and establishes a storm surge nowcasting model by using the long short-term memory (LSTM) neural network algorithm. The results reveal that the LSTM-based nowcasting model has considerable forecasting skills and that the forecasting error is related to the time level advance of the preceding data used. The study also reveals that the forecasting model which only considers the tidal level of the preceding time series has the largest error. Furthermore, the forecasting ability of the model improves to an extent after the atmospheric pressure is taken into account, while the forecasting effect improves more significantly after wind is considered.

Key words: long short-term memory; tropical cyclone; storm surge; nowcasting

收稿日期: 2020-04-08; 修订日期: 2020-05-07

基金项目: 国家重点研发计划 (2016YFC0803107; 2016YFC0803109)

作者简介: 刘媛媛 (1978-), 正高级工程师, 主要从事人工智能技术在减灾行业中的应用研究。电子邮箱: 50237479@qq.com

通讯作者: 张丽, 高级工程师。电子邮箱: ziluolan_123@163.com

风暴潮灾害是指由强烈大气扰动,如热带气旋、温带气旋等引起的,使受其影响的海区的潮位大大地超过平常潮位的海面异常升高现象(Tom, 1983),其造成的直接经济损失占有所有海洋灾害损失的98%以上(Murakami et al, 2015),是沿海城市,尤其是西北太平洋中低纬沿岸城市所面临的一种重要自然灾害(齐庆华等, 2019)。在华南沿海的珠江三角洲,风暴潮的威胁更为严重,这些地区为冲积平原,地势低洼,极易受到风暴潮的侵袭。因此,风暴潮的预测、预警对于这一地区的公共安全有着十分重要的意义,它能为防汛决策和指挥调度提供科学依据,从而减轻灾害损失(中华人民共和国自然资源部, 2018)。

目前对于风暴潮潮位的预报有两种方式。一种是基于数值模式的预报(Provost et al, 2013; 黄世昌等, 2008; 张尧等, 2018; 袁炳等, 2010),即利用大气数值模式与海洋数值模式耦合。另一种方式是基于对历史数据的学习,利用神经网络模型进行预测。目前所使用的神经网络模型主要包括BP神经网络,递归神经网络等(Chen et al, 2007; Yuan et al, 2015; Tseng et al, 2007; 王华等, 2007)。这些神经网络预测模型中,要么只是基于前时序的潮位预测未来的潮位,单纯从数据的角度

分析,没有综合考虑气象因素的影响;要么是只考虑了气象驱动因素,而没有考虑前时序的潮位(薛明等, 2019)。

而风暴潮是一个典型的多因素时序预测问题,不仅仅跟前序潮位有关,还和台风的风速、风向、气压等相关气象条件有关(杨万康等, 2018; 董剑希等, 2016),单纯考虑一种因素通常会引起潮位高度或是潮汐相位的预测误差。

因此本文综合考虑了风速、风向、气压等影响潮位的气象因素和前时序潮位因素,利用LSTM(长短期记忆神经网络)模型,建立风暴潮的临近预报模型,对风暴潮进行预测。

1 数据与方法

1.1 数据

本文所使用的数据包含潮位数据和气象数据。潮位数据为中国广东省深圳市赤湾潮位站(图1)2008—2017年逐时的潮位监测数据。气象数据则为深圳市国家气候观象台赤湾站2008—2017年逐时的气象监测数据,包括风速、风向、气压等。赤湾站位于珠江口东侧,直接与南海相连,其所在区域建筑和码头设施密集,对于风暴潮灾害极为敏感。

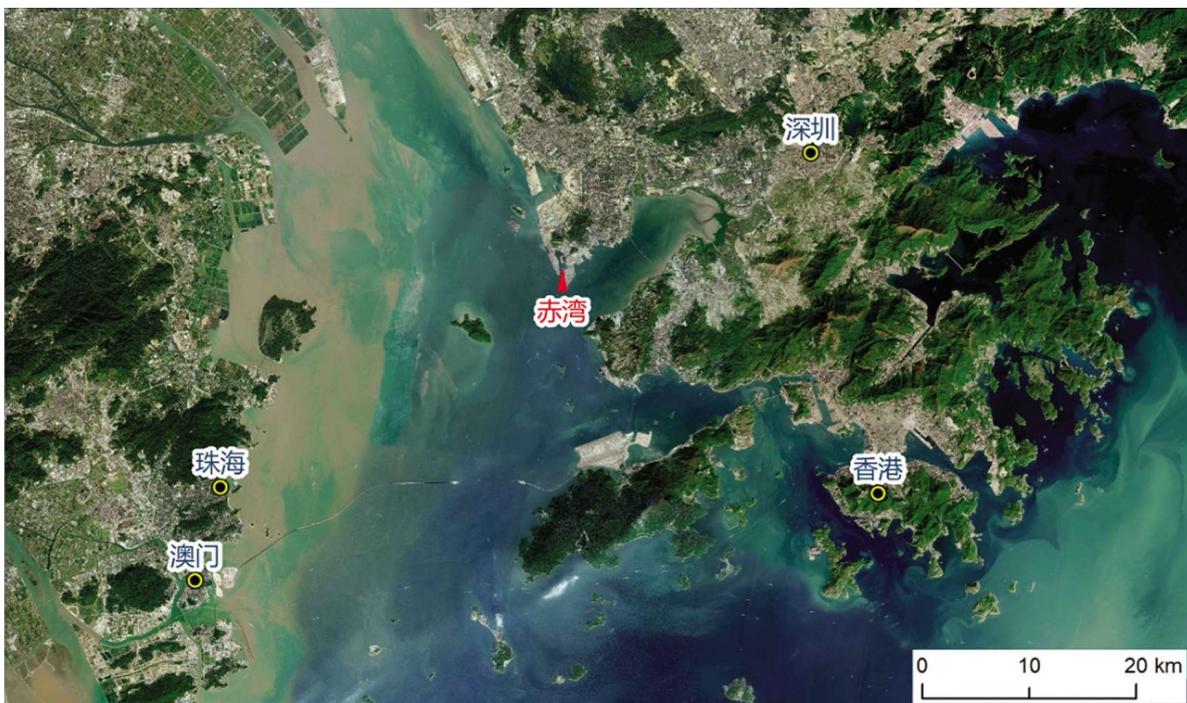


图1 深圳赤湾站所在位置

1.2 LSTM 模型介绍

LSTM (Long Short-Term Memory, 长短记忆) 是在循环神经网络 (Recurrent Neural Networks, RNN) (Elman et al, 1990) 基础上发展起来的。RNN 模型在序列数据训练过程中会出现梯度消失或者梯度爆炸的问题, 导致训练失败。为了解决这个问题, Hochreiter 等 (1997) 对 RNN 模型进行了改进, 提出了 LSTM 模型。LSTM 在隐藏层中增加了一个隐藏状态 C_t , 增加了三个门: 遗忘门、输入门和输出门, 避免了传统 RNN 模型的梯度消失和梯度爆炸的问题, 且比传统的 RNN 模型更精确 (Gers et al, 2000; Monner et al, 2012), 更擅长于处理多个变量的问题, 因此该模型在实际生活中有着广泛的应用 (Michael et al, 2015)。模型的结构如图 2 所示。该模型详细介绍, 本文不再赘述。

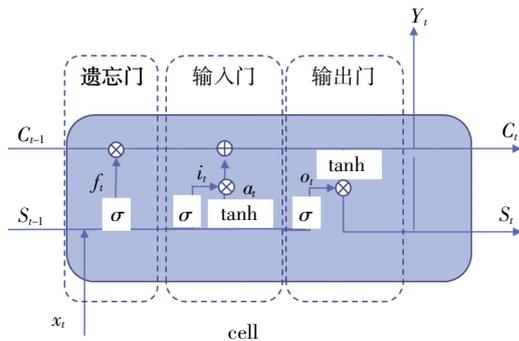


图 2 LSTM 模型结构图

1.3 基于 LSTM 的风暴潮预测模型建立

天文潮汐的变化, 具有很强的周期性, 对天文潮的临近预报相对简单, 目前已经有了非常成熟的预报方法。而风暴潮不仅仅要考虑前时序的影响, 还需考虑很多不确定因素的影响, 预报难度较大 (侯京明 等, 2011)。因此, 本文仅对风暴潮预测模型进行分析。

除了天文潮汐外, 影响风暴潮潮位的因素包括气压、风速、风向等气象要素。尤其是台风临近时, 低气压的抽吸作用会使海平面上升 (Cardenas et al, 2015)。吹向岸的大风, 如果持续时间长且风力大, 会造成大量海水涌上海堤, 造成水位的抬升。如果台风影响恰逢天文高潮位, 会加重风暴潮灾害。因此, 对于风暴潮的预测问题, 实际上是多因素时间序列的预测问题。

本文建立的风暴潮预测模型, 考虑的因素包括

气压、风速、风向以及前时序潮位共 4 个影响因素, 属于 LSTM 模型中多因素输入, 单输出的模型。模型的时间步长为 p , 输入层的神经元 cell 个数 p 个, 隐藏层神经元设为 50 个。取 t 时刻的输出 Y_t 作为预测结果。

将 2008—2016 年总共 78 912 组样本中的 90% 作为训练样本, 以余下的 10% 作为测试样本, 对模型进行训练。利用训练好的模型对 2017 年的潮汐潮位以及两次台风过程引起的风暴潮位进行预测。训练时, 为了避免各类数据数值区间的差异性, 在训练学习之前, 对原始数据做归一化处理, 公式如下:

$$x^{*i} = \frac{x^i - x_{\min}^i}{x_{\max}^i - x_{\min}^i} \quad (1)$$

式中, x^{*i} 为某一类影响因子归一化之后的值, x^i 为原始数值, x_{\min}^i 为该影响因子中的最小值, x_{\max}^i 为其中最大值。

训练时, 训练样本的批次大小 (Batch_size) 为 128, 迭代次数 (Epochs) 为 200, 损失函数为 MAE (平均绝对误差), 优化器 (Optimizer) 为 Adam 算法。最后通过计算预测数据与真实数据的均方根误差 (RMSE) 来评估模型的训练结果。

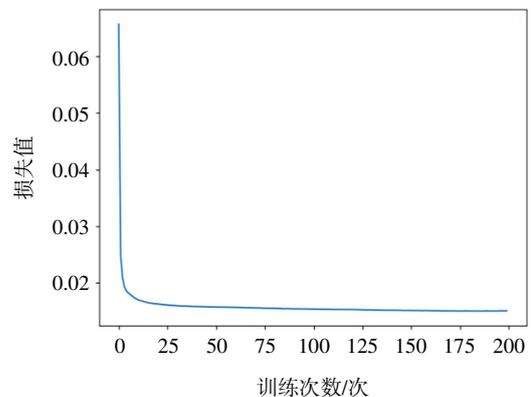


图 3 训练过程中损失曲线图

从图 3 中可以看出, 本模型训练次数在 15 次以内时, 误差迅速下降, 当训练次数达 20 次左右时, 误差曲线就达到了拐点, 误差下降速度逐渐趋于平缓, 模型逐渐收敛。图 4 为模型训练过程中, 实测值和预测值的对比曲线图。从图中可见, 利用本文所建立的模型, 预测误差很小, 能很好地预测出高潮值和低潮值。

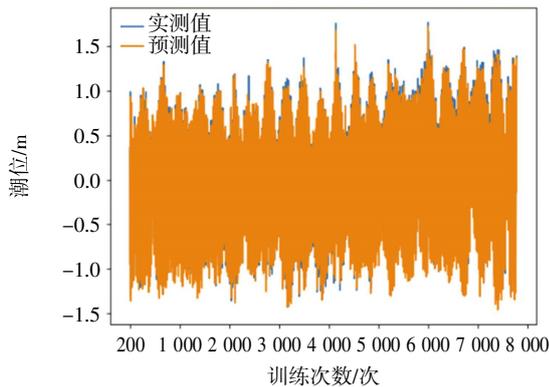


图4 实测值和预测值对比图

2 结果分析与讨论

风暴潮位不仅仅受到前时序潮位的影响，还受到很多气象因素的影响。而不同因素的前时序对风暴潮的影响不同。为了检验模型对于不同影响因素

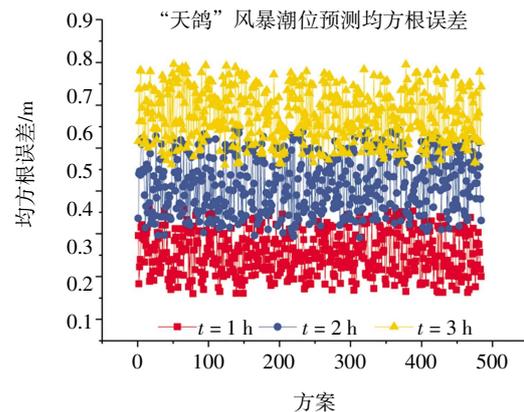
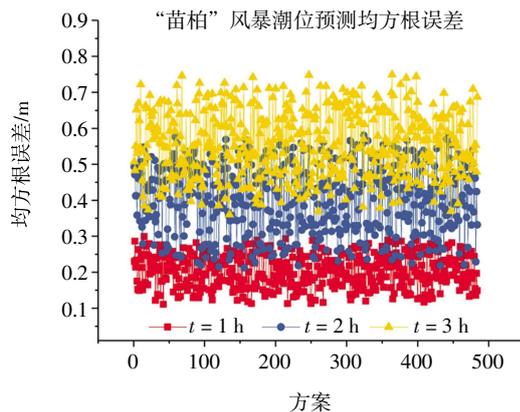


图5 各方案风暴潮预测均方根误差值

表1 预测均方根误差最小的5个方案表

风速	风向	气压	前时序潮位	“苗柏”预测均方根误差/m			“天鸽”预测均方根误差/m		
				$t = 1\text{ h}$	$t = 2\text{ h}$	$t = 3\text{ h}$	$t = 1\text{ h}$	$t = 2\text{ h}$	$t = 3\text{ h}$
2	2	7	7	0.168 4	0.354 9	0.498 0	0.192 3	0.406 2	0.532 8
2	2	6	7	0.189 5	0.357 1	0.508 3	0.192 9	0.409 8	0.549 9
2	1	6	7	0.195 0	0.358 1	0.518 7	0.210 9	0.411 2	0.552 1
2	1	7	7	0.209 9	0.362 1	0.536 8	0.223 4	0.413 9	0.566 7
1	1	5	7	0.213 6	0.415 4	0.549 9	0.227 3	0.422 9	0.580 2

$n_{\text{风向}}$, $n_{\text{前序潮位}}$ 有明显的共同特征,故选取了 $n_{\text{风速}}=2$, $n_{\text{风向}}=2$, $n_{\text{前序潮位}}=7$ 作为输入条件。这说明预报前 2 h 的风速和风向过程、前 7 h 的潮位过程与未来 1~3 h 潮位的相关性最大。而气压这个因素的前时序 n , 对预测潮位的影响, 没有非常明显的特征。

对 LSTM 预测模型而言, 训练样本包含的相关

前时序 n 的敏感性, 选择最优的 n 值, 以训练出更智能的预报模型, 本文选取不同影响因素的前时序 $n = 1 \sim 11$ 进行组合, 作为模型输入条件进行测试。即利用预测时刻的前 1~11 h 的各影响因子, 排列组合成近 500 个输入条件, 对模型进行训练。并利用训练好的模型, 以 2017 年在赤湾站引起较大风暴潮的“苗柏”和“天鸽”为例, 预测其未来 1~3 h 的风暴潮位, 不同方案预测结果的均方根误差 (RMSE) 如图 5 所示。

从图 5 可以看出, 对于不同输入方案的预测结果, LSTM 模型对未来 1 h 风暴潮位的预测, 均方根误差基本在 0.1~0.25 m 之间, 对未来 3 h 风暴潮位的预测, 误差相对较大, 均方根误差 (RMSE) 在 0.5~0.6 m 左右, 最大误差基本在 0.8 m 左右。在所有输入方案中, 选择分析预测误差最小的方案 5。各方案组合及计算误差如表 1 所示。

从表 1 可以看出, 预测误差较小的模型, 其 $n_{\text{风速}}$,

的信息越多, 训练出来的模型越“智能”。分析赤湾站的风暴潮数据和气象数据历史样本发现, 风速明显增加 2 h 以后, 风暴潮位出现大幅度变化, 而更早的风速和风向, 与风暴潮位的相关性不大。风暴潮和天文潮汐也有很强的相关性, 即使台风不强, 如果遇到了高潮, 也可能会造成很高的风暴潮

位。因此，在预测模型中，风速的明显增加信息以及前时序的潮位变化信息都要考虑。赤湾站多年平均落潮历时为 6 h 33 min，平均涨潮历时为 5 h 51 min，前时序 7 h 的潮位数据必然包括最近一个高潮位或低潮位的数据。高潮位和低潮位是潮位数据时间序列的拐点，而包含拐点的信息，有助于模型学习过程中掌握数据时间序列突变的信息。因此选择 $n_{\text{风速}} = 2$ ， $n_{\text{风向}} = 2$ ， $n_{\text{前时序潮位}} = 7$ 的样本序列作为训练样本，包含了风速明显增加的过程和前序潮位序列的 1 个拐点信息，可以得到较好的预测结果。对于气压因素，之前 5 ~ 7 h 的气压数据对未来风暴潮位值，都有一定的影响。

综上，本文最终选择预测误差最小的组合方式，即： $n_{\text{风速}} = 2$ ； $n_{\text{风向}} = 2$ ； $n_{\text{气压}} = 7$ ； $n_{\text{前时序潮位}} = 7$ ，得到最优的智能预测模型，对苗柏和天鸽未来 1 ~ 3 h 风暴潮位预测结果如图 6 所示。图 6 中，黑色的曲线为实测潮位过程，红色的较短曲线标注出了台风过程中的最大潮位。蓝色、绿色和紫色的曲线分别为未来 1 ~ 3 h 的预测结果。从图中可以看出，利用该预测模型，可以很好地对风暴潮进行预测。该模型对未来 2 h、3 h 潮位值和相位的预测，虽然与对提前 1 h 潮位的预测结果相比，误差较大，但

是平均误差也仅在 0.5 m 左右，基本可以满足日常应急需求，而且在时效性上，更有意义。

从图 6 中可以看出，该模型对于这两场台风过程中高潮位极值和相位预测误差较小。其中提前 1 h 预报“苗柏”高潮位极值的误差为 0.41 m，预报“天鸽”高潮位极值的误差为 0.55 m，而且极值相位也吻合得很好。从图 6 中还可以看出，台风“苗柏”经历过程中，出现了两次风暴潮高潮，该模型不仅很好地预测了这两次的高潮位极值的出现，而且高潮位极值和相位的预测效果也很好。

为了进一步分析不同的气象因素和前时序潮位对台风风暴潮的影响情况，分别以“苗柏”和“天鸽”为例，分析各单独气象因素和前时序潮位对赤湾站的风暴潮预测的影响，总共考虑了 4 种情况：(1) 仅考虑前时序潮位影响；(2) 风和前时序潮位的共同影响；(3) 气压和前时序潮位的共同影响；(4) 所有气象要素和前时序潮位的共同影响。在 4 种情况下，对未来 1 h~3 h 风暴潮位预测结果的 RMSE 进行对比，结果如图 7 所示。

从图 7 可以看出，仅考虑前时序潮位影响的预测误差最大，在模型中增加气压要素后会在一定程度上降低预测误差，但改善的程度不如增加风速后

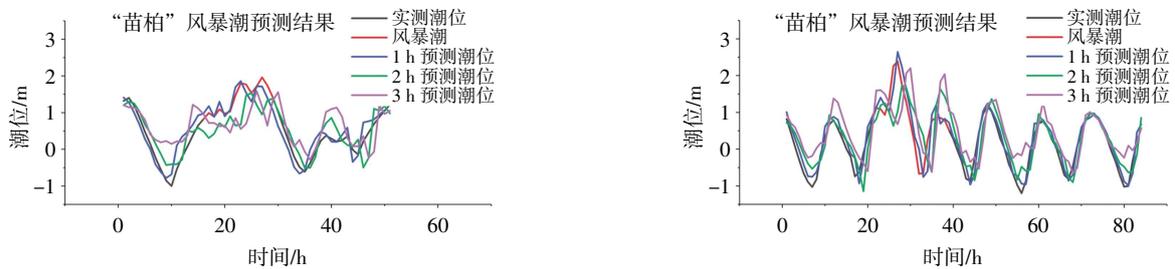


图 6 苗柏和天鸽风暴潮预测结果

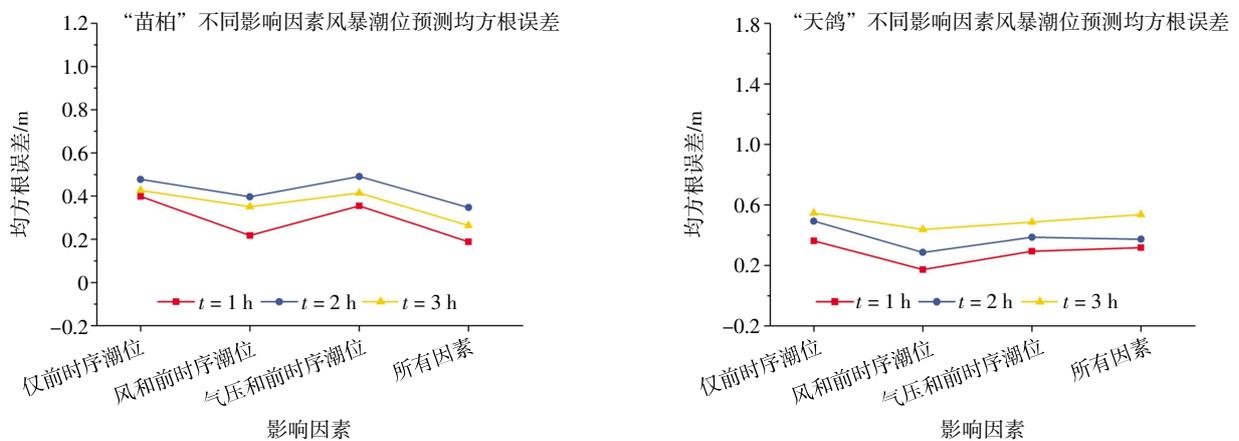


图 7 不同时序及不同气象因素对预测风暴潮的计算误差 RMSE

明显。在“天鸽”台风经历过程中,仅考虑风和前时序潮位的影响,比综合考虑所有气象要素的误差更小;而在“苗柏”过程中,综合考虑所有气象要素得到的预测结果更为准确。这组实验表明,风对风暴潮的影响可能要大于气压,而要想更准确地预报风暴潮潮位,对风的要素应该考虑得更充分。

4 结论

本文建立了一个基于多因子 LSTM 算法的潮位临近预报模型,该模型可利用气压、风速、风向等气象观测数据以及前时序潮位观测数据,对未来 1~3 h 的潮位高度进行预测。利用位于珠江口东岸的赤湾站的 2008—2016 年逐时潮位资料和气象数据,对模型进行了训练,并对 2017 年两场台风的风暴潮进行了预测检验。从对两次风暴潮过程的检验可以看出,并非考虑的影响因素越多,所得结果越合理,影响因素的贡献应充分给予评价后再确定是否作为输入量。

结果表明,基于 LSTM 的临近预报模型具有相当的预报技巧,预报误差与所选用的输入影响因素及其前序时次 n 有关。在所有的计算方案中,利用前 2 个小时的风速和风向过程数据,前 7 个小时的潮位过程数据建立的模型对未来 1~3 h 天文潮和风暴潮位的预测误差最小,均可以达到满意的结果。其中对未来 1 h 预测结果误差最小,误差在 0.1~0.25 m 左右,对未来 2~3 h 预测结果均方根误差在 0.5~0.6 m 左右,可以满足日常应急工作的需求,而且在时效性上更有意义。

为了进一步分析各气象要素对风暴潮的影响,本文还考虑了 4 种不同输入参数的组合,对预测效果进行了进一步的检验,发现仅考虑前时序潮位的预测模型误差最大,考虑气压后模型的预测能力有一定进步,而考虑风之后,预测的效果提升更为明显,体现为潮位的预测误差明显减小。这或许暗示着在未来的风暴潮预测研究中,对风的影响应更为关注。

参 考 文 献

董剑希,李涛,侯京明,2016.福建省风暴潮时空分布特征分析[J].海洋通报,35(3):331-339.
侯京明,于福江,原野,等,2011.影响我国的重大台风风暴潮时空分

- 布[J].海洋通报,30(5):535-539.
黄世昌,李玉成,赵鑫,等,2008.浙江沿海超强台风作用下风暴潮增水数值分析[J].海洋工程,26(3):58-64.
齐庆华,蔡榕硕,颜秀花,2019.气候变化与我国海洋灾害风险治理探讨[J].海洋通报,38(4):361-367.
王华,姚圣康,龚茂珣,等,2007.东海区域灾害性海浪长期预测方法研究[J].海洋通报,26(5):35-42.
薛明,李醒飞,成方林,2019.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,38(3):290-295.
杨万康,杨青莹,张峰,等,2018.典型海湾风暴潮特征数值模拟与研究[J].海洋通报,37(5):537-547+564.
袁炳,费建芳,王云峰,等,2010.一种非对称台风 Bogus 方法的数值模拟应用[J].海洋通报,29(2):187-193.
张尧,谢欣,陶爱峰,等,2018. Boussinesq 相位解析的海岸水动力学数学模型研究进展[J].海洋通报,37(5):481-493.
中华人民共和国自然资源部.中国海洋灾害公报(2003-2018),2018.
CARDENAS M B, BENNETT P C, ZAMORA P B, et al, 2015. Devastation of aquifers from tsunami-like storm surge by Super typhoon Haiyan[J]. Geophysical Research Letters, 42(8):2844-2851.
CHEN B F, WANG H D, CHU C C, 2007. Wavelet and artificial neural network analyses of tide forecasting and supplement of tides around Taiwan and South China Sea[J]. Ocean Engineering, 34(16):2161-2175.
Elman J L, 1990. Finding Structure in Time[J]. Cognitive Science, 14(2):179-211.
GERS F A, SCHMID HUBER, et al, 2000. Learning to Forget: Continuous Prediction with LSTM[J]. Neural Computation, 12(10):2451-2471.
HOCHREITER S, SCHMIDHUBER J, 1997. Long Short-Term Memory [J]. Neural computation, 9(8):1735-1780.
MICHAEL NIELSEN, 2015. Neural Networks and Deep Learning[M]. Determination Press.
Monner D, Reggia J A, 2012. A generalized LSTM-like training algorithm for second-order recurrent neural networks[J]. Neural Networks, 2012(25):70-83.
MURAKAMI T, SHIMOKAWA S, YOSHINO J, et al, 2015. A new index for evaluation of risk of complex disaster due to typhoons[J]. Natural Hazards, 79(1):29-44.
PROVOST C L, MARIE-LAURE GENCO, LYARD F, 2013. Modeling and Predicting Tides Over the World Ocean[M]. Quantitative Skill Assessment for Coastal Ocean Models. American Geophysical Union(AGU).
TOM BEER, 1983. Environmental Oceanography[M]. Pergamon Press.
TSENG C M, JAN C D, WANG J S, et al, 2007. Application of artificial neural networks in typhoon surge forecasting[J]. Ocean Engineering, 34(11-12):1757-1768.
YUAN H, TAN M, WANG W, 2015. Selection of Methods for Predicting Tidal Levels with a Typhoon Surge Effect[J]. Journal of Coastal Research, Special Issue (73):337-341.

(本文编辑:王少朋)