

基于NARX神经网络的极端风暴潮事件预报研究

赵宏凯, 迟万清*, 杨洁, 周涛

(自然资源部第一海洋研究所, 山东 青岛 266061)

摘要: 通过构建采用外部输入的非线性自回归神经网络(NARX), 利用1979年1月1日00时—2003年12月25日23时逐时的实测潮位数据和再分析气象数据结合调和分析预报结果搭建模型, 对库克斯(Cuxhaven)港口2004—2018年中增水最大的两次风暴潮极端事件潮位进行预报和验证, 同时对影响模型性能的参数进行量化分析。结果表明: 在NARX神经网络延迟数为24 h时模型的精度最高, 两次极端风暴潮验证下的 R^2 分别为0.94和0.95, 且在最高潮位时的误差分别为57.78 cm和26.55 cm。实验中模型在延迟数方面存在阈值, 当延迟数为24 h时模型效果最佳, 在延迟数达到阈值前模型的精度逐渐上升, 超过该阈值后模型精度下降; 输入时间数据序列的长短会影响模型的精度, 序列越长模型精度越高, 但影响效果会逐渐降低。

关键词: NARX神经网络; 风暴潮潮位; 潮位预报

中图分类号: P731.23 **文献标识码:** A **文章编号:** 1003-0239(2023)03-0011-08

0 引言

风暴潮是指在强烈的大气扰动下, 如强风和气压骤变等条件引起的海面异常升高的现象。极端潮汐事件的频繁发生不断影响着世界许多地方的社会和环境^[1-3]。根据美国国家海洋和大气管理局(National Oceanic and Atmospheric Administration, NOAA)的数据, 1993—2018年间, 全球海平面升高了81 mm, 并且上升速度逐渐加快。在极端天气下潮位暴涨所带来的灾害风险愈加增大, 因此潮位预测非常重要。

目前预测极端天气下风暴潮的经典方法包括经验统计方法和数值模拟方法。经验统计方法是根据大量历史风暴潮数据, 用数理统计的方法, 对影响风暴潮增水的各项数据进行统计, 从而计算出风暴增水与其影响因素之间的关系。曾德美^[4]根据青岛港多年水位数据提出了青岛港增减水的经验公式; 郭文云等^[5]将多源数据进行整合并构建了集

合样本用于风暴潮预报。数值模拟方法则是一种更直接的方法。它从流体力学角度出发, 根据风到达近岸时的风速、风向、气压等气象数据, 基于动力学模式以及风暴控制方程等计算得出风暴增水。目前国内基于ADCIRC(A Parallel Advanced Circulation Model For Oceanic, Coastal and Estuarine Waters)^[6-8]、FVCOM(Finite - Volume Coastal Ocean Model)^[9]、河口海岸海洋模式(Estuarine Coastal Ocean Model-Semi-Implicit, ECOM-SI)^[10]等模型或模式对风暴潮进行了模拟, 取得的效果也很显著。然而, 传统的经验统计方法和数值模拟方法要求研究人员对风暴潮动力学相关知识有着非常深入的了解, 通常需要进行大量的计算并且很难得出一个准确的模型。

随着近几年机器学习的发展以及技术的突破^[11], 人工神经网络(Artificial Neural Network, ANN)^[12-15]、卷积神经网络(Convolutional Neural Network, CNN)^[16]、支持向量机(Support Vector

收稿日期: 2022-06-21。

基金项目: 国家重点研发计划(2022YFC2803800)。

作者简介: 赵宏凯(1997-), 男, 硕士在读, 主要从事数值模拟研究工作。E-mail: 386796548@qq.com

*通信作者: 迟万清(1975-), 男, 正高级工程师, 硕士, 主要从事数值模拟研究工作。E-mail: 350018185@qq.com

Machines, SVM)^[17]等新兴方法也逐渐被应用于风暴潮预报。李未等^[18]根据潮位数据并利用误差反向传播(Back Propagation, BP)神经网络建立了台风风暴潮和天文潮的综合增水效应预报模型,并对台风期间的增水进行预测;在此基础上,卢君峰等^[19]在模型中增加了风速、气压等输入因子,使得模型的预报精度得到了提高;雷森等^[20]利用递归神经网络(Recursive Neural Network, RNN)预测了风暴潮增水。基于外部输入的非线性自回归(Nonlinear Autoregressive Model with Exogenous Inputs, NARX)神经网络是将天文潮和非天文潮作为预报潮位输入,预报结果与实际潮位相差很小。相较于传统的静态BP神经网络和ANN, NARX在网络中加入了动态的延时和反馈机制,能够将网络输出反馈到输入,使得其对时间序列数据有更好的学习效率,非线性拟合能力强,短期预测精度高。但是目前NARX在极端风暴潮潮位预报中的应用还较少。

本文利用欧洲中期天气预报中心(European Centre for Medium-range Weather Forecasts, ECMWF)的ERA5再分析数据集,将库克斯港(Cuxhaven)1979年1月1日00时(世界时,下同)—2003年12月25日23时逐时的风速、风向、压强和实测潮位数据,以及 t_{tide} 模型预报的天文潮位作为输入搭建神经网络模型,并与传统BP神经网络作对比,同时挑选2004—2018年两场增水最大的风暴潮事件进行验证,以期为智能化风暴潮预警提供一定的技术支撑。

1 研究数据和方法

1.1 研究区域以及数据资料

库克斯港(53°52′1.2″N, 8°43′1.2″W)作为德国第二大渔港,位于易北河(Elbe River)汇入北海(North Sea)的入口,地理位置十分重要,也是著名的船舶制造和航运业基地,港口附近具有大量工业设施和居住地,因此预防极端天气风暴潮非常关键。

实验中的风速、风向、气压数据来自于ECMWF的ERA5再分析数据集,它是欧洲中期天气预报中心最新的再分析产品。相比于之前的ERA-Interim, ERA5同化系统使用了若干专为再分析而开发的综合预报系统(Integrated Forecasting System, IFS)

cycle 41r2。对比之前ERA数据产品中存在的波浪、波高、风速等数据预报偏低的现象, ERA5在预报准确性方面得到了较大的改进。本研究将风向拆解为 u 分量和 v 分量,并设置正北和正东为正方向;天文潮位采用 t_{tide} 模型计算得出。通过对该地点的实测潮位进行计算获得所在位置的调和常数,并利用该调和常数进行天文潮位的预报。本文的实测潮位数据来自夏威夷大学海平面中心(University of Hawaii Sea Level Center, UHSLC),测站位置位于德国下萨克森州(Lower Saxony)库克斯港。

1.2 研究方法

1.2.1 BP神经网络

BP神经网络是一种按误差逆向传播算法训练的多层前馈网络,是目前应用最广泛的神经网络模型之一。它一般具有3层或以上的神经网络,包括输入层、隐含层和输出层。BP神经网络能学习和贮存大量的输入-输出模式映射关系,使用最快速下降算法,通过反向传播来不断调整网络的权值和阈值,使网络误差的平方和最小,具有很强的非线性映射能力。

1.2.2 NARX神经网络

NARX神经网络是由相互连接的节点组成的一种动态网络,它可以接受一个或多个输入,获得神经元与输入参数之间连接的最优权值。相较于传统的静态BP神经网络, NARX加入了延时和反馈机制,它可对输入因子的历史数据进行储存,并将网络的输出向量延迟保持之后,通过外部反馈,一起引入到输入向量中,极大地增强了对历史数据的记忆能力,是一种动态的神经网络。与长短时记忆(Long Short-Term Memory, LSTM)神经网络相比,两者都在非线性拟合方面具有非常好的效果,且在短期内的预测结果相近^[21],但是由于每一个LSTM的cell里面都具有4个全连接层,因而在长时间跨度建模中,当网络很深时计算量非常巨大。本文所预报的风暴潮周期为96 h,在较短预报时效内选择NARX神经网络的效率更高。

NARX神经网络的基本结构为:

$$\begin{aligned} y(t) = & f(y(t-1), y(t-2), \dots, y(t-n_y), \\ & u(t-1), u(t-2), \dots, u(t-n_u)) \end{aligned} \quad (1)$$

式中: $u(t)$ 和 $y(t)$ 分别是该神经网络在 t 时刻的输入和输出; n_u 为输入延迟的最大阶数, n_y 为输出延迟的最大阶数; $u(t-1), u(t-2), \dots, u(t-n_u)$ 表示相对于 t 时刻的历史输入; $y(t-1), y(t-2), \dots, y(t-n_y)$ 是相对于 t 时刻的历史输出。

该神经网络包含输入层、隐含层、输出层3层(见图1)。图中 $x(t)$ 是本文的输入向量,即风速、风向、气压、天文潮位; $y(t)$ 为被预测量; n 为网络中的延迟时间; w 是隐含层到隐含层之间的权重; b 为神经元的偏置。输入层包含神经网络的各项输入参数,隐含层是驶入输入—输出的计算步骤,输出层是模型预测的结果。NARX神经网络的特点是输出层的结果会同时反馈给输入层。本研究中隐含层采用的激活函数为tansig(双曲正切sigmoid传递函数),输出层采用的激活函数为purelin(线性传递函数)。




图1 NARX神经网络结构

Fig.1 NARX neural network structure

1.2.3 参数选取

在模型参数的选取上,神经元数量、输入和输出的最大延迟阶数、训练算法等参数均会影响模型的性能,但是目前参数选取没有完全成熟的方法。本文采取控制变量的实算方法结合经验统计方法来确定神经元参数以及选取训练算法。

在BP神经网络和NARX神经网络神经元参数选取上,本文分别选取神经元数量为10、25、50、75和100对模型进行训练并对两场风暴潮进行预报,最终确定了BP神经网络在神经元数量为75时,模型达到最佳效果,决定系数(R^2)分别达到0.29和0.78;NARX神经网络在神经元数量为50时,模型达到最佳效果, R^2 分别达到0.94和0.95。

在3种常用的训练算法中,LM(Levenberg-Marquardt)算法是一种利用梯度求最值的算法。它

使用了带阻尼的高斯-牛顿方法,同时具备梯度法和牛顿法的优点^[22],当数据量较少时收敛速度快,具备很好的线性拟合效果,但当计算量变大时,其收敛速度会呈现非线性的高增长^[23]。量化共轭梯度算法(Scaled Conjugate Gradient, SCG)是一种介于最速下降法和牛顿法之间的方法^[24],它沿着共轭的方向搜索,收敛速度比一般梯度下降法快得多,同时在过程中不必计算或储存二阶导数信息,与牛顿法相比计算代价很低^[25],但是其收敛性极度依赖 K 矩阵。贝叶斯正则化(Bayesian Regularization, BR)的基本思想是保留所有的特征量,通过减少参数 θ 来避免某个特征量的影响过大,同时约束网络权值的大小,这能在一定程度上抑制模型的过拟合,使其具有抗噪能力以更好地预测未来^[26]。因此本文采取的训练算法为贝叶斯正则化算法。

1.3 评价指标

NARX模型的性能可由以下评价指标判断: R^2 可以用来评估模型预测结果和真实值之间的差异;均方根误差(E_{RMS})表示预测值和真实值之间均方差的平方根,可用来衡量观测值与真实值之间的偏差;平均绝对误差(E_{MA})表示预测值的平均误差大小。这3个量被定义为:

$$R^2 = 1 - \frac{\sum_i (y_i - f_i)^2}{\sum_i (y_i - \hat{y})^2} \quad (2)$$

$$E_{\text{RMS}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - f_i)^2} \quad (3)$$

$$E_{\text{MA}} = \frac{1}{m} \sum_{i=1}^m |y_i - f_i| \quad (4)$$

式中: y_i 表示真实值; f_i 表示预测值; \hat{y} 表示真实值的平均值。这3个量能够较好地衡量模型的性能。

2 实验结果

2.1 模型性能验证

该NARX神经网络模型使用了1979年1月1日00时—2003年12月25日23时库克斯港219 000条逐时的风速、风速 u 分量、风速 v 分量、 t_{tide} 天文潮位数据作为模型输入进行计算,并预报了2004—2018年两场增水最大的极端风暴潮事件,模拟结果与实况较吻合,表明基于NARX神经网络的风暴潮

预报取得了很好的效果。图2a展示了NARX延迟数为24 h时模型训练集、验证集以及总体的表现结果,图2b展示了BP神经网络神经元数为75时的模型训练集、验证集以及总体的表现结果。从图中可以看出,相对于传统BP神经网络,NARX神经模型在训练以及预报极端天气风暴潮事件中具有优越性。

2.2 模型预测验证

2.2.1 风暴潮预测

本文选择了2004—2018年两次增水值最大的风暴潮,分别发生在2007年11月7日00时—11日00时(风暴潮事件1)以及2017年10月27日00时—31日00时(风暴潮事件2)。选取这两个时间段各自96 h进行模型验证。从图3中可以明显地看到,在神经元数一定的情况下,随着延迟数的增加,风

暴潮预测效果更好,在延迟数为24 h时效果达到最佳,当延迟数达到36 h时精度稍下降。图4展示了在最佳延迟数24 h下NARX神经网络与传统BP神经网络的比较,从中可以明显看出在两场风暴潮事件中,BP神经网络的模拟结果与实测值差距较大,反映了BP神经网络在多变量、长数据条件下对于极端风暴潮事件模拟的不足。

在风暴潮事件1中,基于NARX神经网络的潮位预报效果很好。由表1可见,在一定范围内,随着延迟数的增加,模型的拟合效果越来越好,在延迟数为24 h时效果最佳($R^2=0.94$, $E_{\text{RMS}}=32.09$ cm, $E_{\text{MA}}=23.08$ cm),且最大潮位的峰值误差为57.78 cm。同样在风暴潮事件2中也取得相似效果。由表2可见,在延迟数为24 h时效果最佳($R^2=0.95$, $E_{\text{RMS}}=24.55$ cm, $E_{\text{MA}}=19.62$ cm),最大潮位的峰值误差为26.55 cm。同时还可以发现,本次实验的NARX神

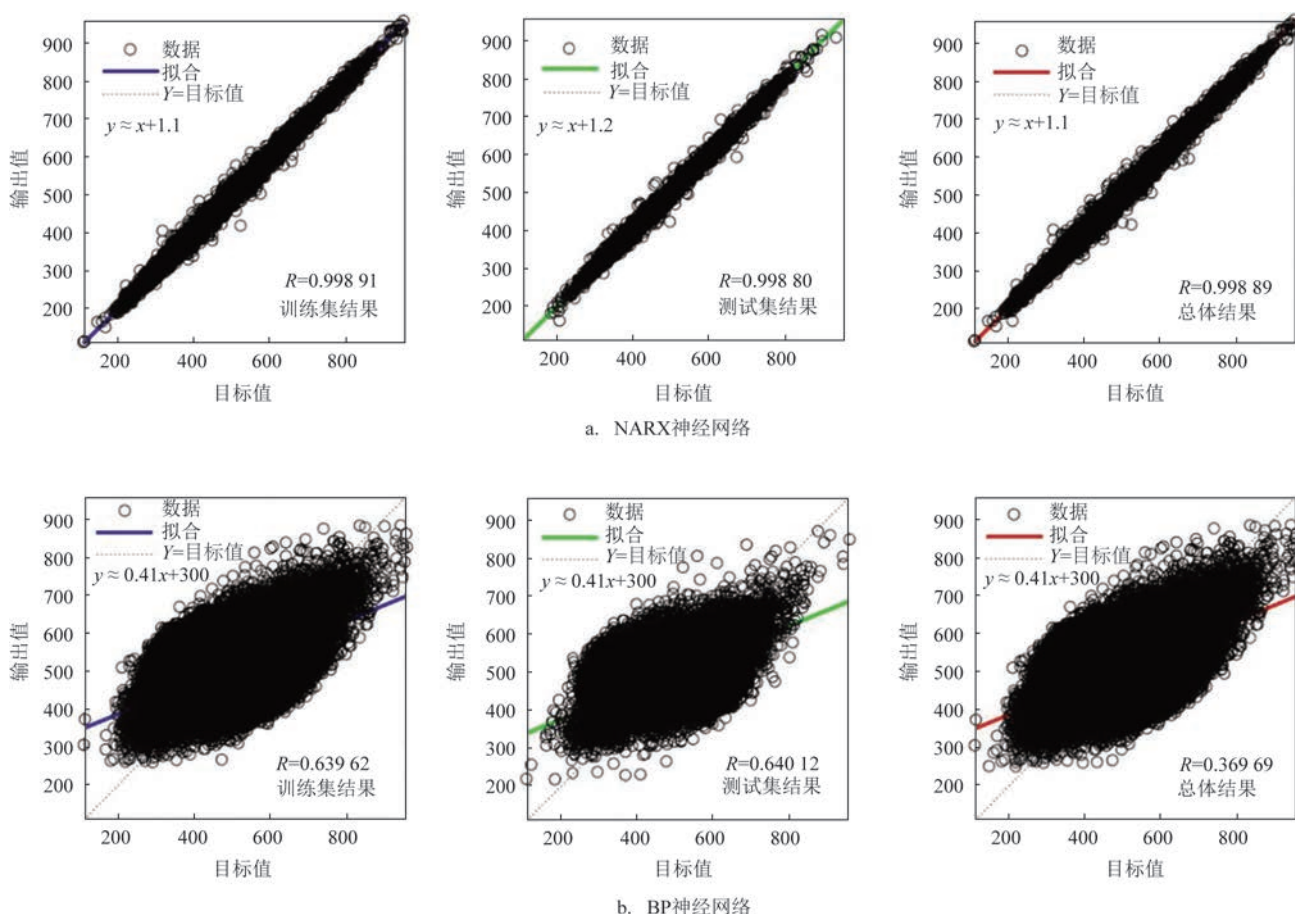


图2 NARX神经网络和BP神经网络模型训练结果

Fig.2 NARX neural network and BP neural network model training results




图3 风暴潮事件1和2中NARX神经网络不同延迟数量预测值与实测值的比较

Fig.3 Comparison of NARX model predicted value and measured value of storm surge events 1 and 2 with different delay numbers




图4 风暴潮事件1和2中两种不同神经网络比较

Fig.4 Comparison of two different neural networks for storm surge events 1 and 2

表1 风暴潮事件1 NARX不同延迟数模型与BP神经网络误差比较

Tab.1 Comparison of errors between NARX models with different delay numbers and BP neural network for storm surge event 1

参数	NARX神经网络						BP神经网络
延迟/h	3	6	12	24	36		—
R^2	0.81	0.90	0.91	0.94	0.89		0.29
E_{RMS}/cm	54.91	41.32	38.76	32.09	42.05		107.96
E_{MA}/cm	42.10	30.92	28.17	23.08	33.63		90.01

表2 风暴潮事件2 NARX不同延迟数模型与BP神经网络误差比较

Tab.2 Comparison of errors between NARX models with different delay numbers and BP neural network for storm surge event 2

参数	NARX神经网络						BP神经网络
延迟/h	3	6	12	24	36		—
R^2	0.58	0.67	0.78	0.95	0.93		0.78
E_{RMS}/cm	67.60	59.99	48.71	24.55	26.70		48.19
E_{MA}/cm	54.40	46.64	35.02	19.62	21.02		37.61

神经网络在延迟数方面存在阈值,在延迟数达到 24 h 之前,模型性能随着延迟的增加而增加,超过 24 h 后模型性能会随着延迟的增加而下降。这两个时间段的风暴潮的预测情况都验证了该 NARX 神经网络在预测风暴潮方面的可靠性。

2.2.2 时间序列影响分析

本节讨论了时间序列输入的长短对模型精度的影响,判断减少输入数据是否影响神经网络的精度。根据 2.2.1 节的结果,采用相同神经元数量以及效果最好的 24 h 延迟,时间序列分别为 6 M、1 a、2 a、4 a 和 25 a,并选择 2007 年 11 月 7 日 00 时—11 日 00 时的最大风暴潮作为模型验证,结果见图 5。从图中可以看到,当时间序列长度为 6 M 时,模型的拟合效果非常差,随着时间序列的增长,模型的拟合效果越来越好。从评价指标也可看出(见表 3),在数据时间序列为 6 M 时,模型对于风暴潮的拟合效果欠佳, R^2 仅为 -1.719 8,当序列增长时, R^2 显著增加,但增长幅度减缓。




图 5 风暴潮事件 1 不同时间序列模型预测值与实测值比较

Fig.5 Comparison of predicted and measured values of different time series models for storm surge event 1

表 3 风暴潮事件 1 不同时间序列长度模型误差比较

Tab.3 Comparison of Model Errors of Different Time Series Lengths for Storm Surge Event 1

参数	时间序列长度				
	6 M	1 a	2 a	4 a	25 a
R^2	-1.53	0.54	0.78	0.87	0.94
E_{RMS}/cm	202.47	88.29	62.43	48.82	32.09
E_{MA}/cm	148.29	79.02	50.81	36.29	23.08

2.3 讨论

本节验证了 NARX 神经网络模型对库克斯港地区极端风暴潮事件的预报情况,从延迟数以及训练数据输入的长短两方面验证了该网络的性能,并用 R^2 、 E_{RMS} 、 E_{MA} 3 个评价指标对 NARX 模型和 BP 神经网络在极端风暴潮事件预报中的精度、模型效果进行评价。相较于刘墨阳等^[27]和 NUNNO 等^[28]的研究,本文使用了更长时间尺度的数据建立网络模型,同时在研究中评估了 NARX 模型的时间敏感度。

实验结果表明,训练数据输入的长短会显著影响模型对于风暴潮的预测程度。当数据序列较短时,模型精度很差,随着序列长度的增加,模型精度会逐渐上升,但是上升幅度变缓;相较于 NARX 模型,BP 神经网络不适合做长时间序列的模型构建以及极端风暴潮事件的预报。当 NARX 网络神经元数量一定时,在一定范围内,随着延迟数的增加,模型精度会上升,当延迟数为 24 h 时模型效果最好,但延迟数超过 24 h 后模型精度反而会下降。

3 结论与展望

本文基于 NARX 神经网络,利用大量的数据和实验讨论了 NARX 神经网络在长期风暴潮预测方面的可行性,并验证了其准确度和性能。结果表明 NARX 神经网络在预测极端风暴潮事件中具有很好的效果,在两次风暴潮事件的预报中,在延迟数为 24 h 时, R^2 达到了 0.94 和 0.95,表现出很强的相关性,同时在最高峰值时的误差分别为 57.78 cm 和 26.55 cm。但是,研究同时发现,利用该模型预报极端风暴潮需要准确的风速、风向以及压强等数据,因此数据的获取及其准确度的确认仍是未来需要解决的问题。利用神经网络进行极端风暴潮预报为智能化海洋预报提供了一个重要的思路,相较于传统方法,神经网络更加灵活快捷,未来能够在防灾减灾等领域发挥更加重要的作用。

参考文献:

- [1] SPENCER T, BROOKS S M, EVANS B R, et al. Southern North Sea storm surge event of 5 December 2013: Water levels, waves and coastal impacts[J]. Earth-Science Reviews, 2015, 146: 120-145.

- [2] JENSEN J, ARNS A, WAHL T. Yet another 100Yr storm surge event: the role of individual storm surges on design water levels[J]. *Journal of Marine Science and Technology*, 2015, 23(6): 882-887.
- [3] CAVALERI L, BAJO M, BARBARIOL F, et al. The October 29, 2018 storm in Northern Italy-an exceptional event and its modeling [J]. *Progress in Oceanography*, 2019, 178: 102178.
- [4] 曾德美. 青岛港风暴潮经验统计预报[J]. *海洋预报*, 1992, 9(3): 66-73.
- ZENG D M. A statistical forecasting of storm surge in Qingdao Harbor[J]. *Marine Forecasts*, 1992, 9(3): 66-73.
- [5] 郭文云, 安佰超, 裘诚, 等. 基于多源数据的台风风暴潮概率预报研究: 台风集合的构建[J]. *海洋预报*, 2021, 38(1): 26-33.
- GUO W Y, AN B C, QIU C, et al. Probabilistic forecast for typhoon storm surge based on multi-source data: creation of typhoon ensemble[J]. *Marine Forecasts*, 2021, 38(1): 26-33.
- [6] 张敏, 罗军, 胡金磊, 等. 雷州市沿海风暴潮淹没危险性评估[J]. *热带海洋学报*, 2019, 38(2): 1-12.
- ZHANG M, LUO J, HU J L, et al. Inundation risk assessment of storm surge along Lei Zhou coastal areas[J]. *Journal of Tropical Oceanography*, 2019, 38(2): 1-12.
- [7] 韩雪, 盛建明, 潘锡山, 等. 南黄海海域风暴潮精细化数值模式研究[J]. *海洋预报*, 2019, 36(1): 52-58.
- HAN X, SHENG J M, PAN X S, et al. Study on the refined storm surge numerical model in the Southern Yellow Sea[J]. *Marine Forecasts*, 2019, 36(1): 52-58.
- [8] 傅赐福, 董剑希, 刘秋兴, 等. 1409 号和 1415 号台风风暴潮预报的数值研究[J]. *海洋预报*, 2016, 33(4): 26-33.
- FU C F, DONG J X, LIU Q X, et al. Numerical simulation study on typhoon "Rammasun" (1409) and typhoon "Kalmaegi" (1415) storm surge forecast[J]. *Marine Forecasts*, 2016, 33(4): 26-33.
- [9] 曹丛华, 白涛, 高松, 等. 胶州湾高分辨率三维风暴潮漫滩数值模拟[J]. *海洋科学*, 2013, 37(2): 118-125.
- CAO C H, BAI T, GAO S, et al. High resolution 3D storm surge and inundation numerical model used in the Jiaozhou Bay[J]. *Marine Sciences*, 2013, 37(2): 118-125.
- [10] 端义宏, 朱建荣, 秦曾灏, 等. 一个高分辨率的长江口台风风暴潮数值预报模式及其应用[J]. *海洋学报*, 2005, 27(3): 11-19.
- DUAN Y H, ZHU J R, QIN Z H, et al. A high-resolution numerical storm surge model in the Changjiang River estuary and its application[J]. *Acta Oceanologica Sinica*, 2005, 27(3): 11-19.
- [11] SCHMIDHUBER J. Deep learning in neural networks: an overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [12] 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.
- [13] LEE T L, JENG D S. Application of artificial neural networks in tide-forecasting[J]. *Ocean Engineering*, 2002, 29(9): 1003-1022.
- [14] PROUTY D B. Using artificial neural networks to predict storm surge in the North Sea and the Thames Estuary[D]. Southampton: University of Southampton, 2007.
- [15] SHETTY R, DWARAKISH G S. Prediction of tides using neural networks at Karwar, west coast of India[J]. *Development and Applications of Oceanic Engineering*, 2013, 2(3): 77-85.
- [16] LEE J W, IRISH J L, BENSI M T, et al. Rapid prediction of peak storm surge from tropical cyclone track time series using machine learning[J]. *Coastal Engineering*, 2021, 170: 104024.
- [17] 张广平, 彭世球, 张晨晓. 一种融合多因素的 MOS 风暴潮灾害过程模拟研究[J]. *安全与环境工程*, 2019, 26(3): 50-55.
- ZHANG G P, PENG S Q, ZHANG C X. A simulation study of MOS storm surge disaster process with multiple factors[J]. *Safety and Environmental Engineering*, 2019, 26(3): 50-55.
- [18] 李未, 王如云, 卢长娜, 等. 神经网络在珠江口风暴潮预报中的应用[J]. *热带海洋学报*, 2006, 25(3): 10-13.
- LI W, WANG R Y, LU C N, et al. Forecast of storm surge in Zhujiang River estuary by means of artificial neural network[J]. *Journal of Tropical Oceanography*, 2006, 25(3): 10-13.
- [19] 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.
- [20] 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.
- [21] 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 X, DING J. Study on the correction technology of tide level forecast based on deep learning[J]. *Marine Forecasts*, 2022, 39(2): 70-79.
- [22] MARQUARDT D W. An algorithm for least-squares estimation of nonlinear parameters[J]. *Journal of the Society for Industrial and Applied Mathematics*, 1963, 11(2): 431-441.
- [23] 李国民, 宿梦瑶, 朱代先. 光束平差法中的一种改进 LM 算法[J]. *西安科技大学学报*, 2022, 42(1): 152-159.
- LI G M, SU M Y, ZHU D X. An improved LM algorithm in bundle adjustment[J]. *Journal of Xi'an University of Science and Technology*, 2022, 42(1): 152-159.
- [24] HESTENES M R, STIEFEL E. Methods of conjugate gradients for solving linear systems[J]. *Journal of Research of the National Bureau of Standards*, 1952, 49(6): 409-436.
- [25] 苏高利, 邓芳萍. 论基于 MATLAB 语言的 BP 神经网络的改进算法[J]. *科技通报*, 2003, 19(2): 130-135.
- SU G L, DENG F P. On the improving backpropagation algorithms of the neural networks based on MATLAB language: a

- review[J]. Bulletin of Science and Technology, 2003, 19(2): 130-135.
- [26] FORESEE F D, HAGAN M T. Gauss-newton approximation to Bayesian learning[C]//Proceedings of International Conference on Neural Networks. Houston: IEEE, 1997: 1930-1935.
- [27] 刘墨阳, 李巧玲, 李致家, 等. 基于小波分析的NARX神经网络在水位预测中的应用[J]. 南水北调与水利科技, 2019, 17(5): 56-63.
- LIU M Y, LI Q L, LI Z J, et al. The application of NARX neural network model based on wavelet analysis for water level prediction[J]. South-to-North Water Transfers and Water Science & Technology, 2019, 17(5): 56-63.
- [28] NUNNO F D, DE MARINIS G D, GARGANO R, et al. Tide prediction in the Venice lagoon using nonlinear autoregressive exogenous (NARX) neural network[J]. Water, 2021, 13(9): 1173.

Extreme storm surge event forecasting based on a NARX neural network

ZHAO Hongkai, CHI Wanqing*, YANG Jie, ZHOU Tao

(First Institute of Oceanography, Ministry of Natural Resources, Qingdao 266061, China)

Abstract: Using hourly tide level measurements from 00:00 on January 1, 1979 to 23:00 on December 25, 2003, meteorological reanalysis data, and reconciliation analysis of the forecast results, a storm surge forecasting model based on a nonlinear autoregressive model with exogenous inputs (NARX) neural network is conducted and validated in two storm surge extreme events with the largest water gain in Cuxhaven harbor from 2004 to mid-2018. The effects of the model parameters on the model's performance are quantitatively assessed. The results show that the model's accuracy is the highest when the NARX neural network's delay number is 24 hours, and the R^2 is 0.94 and 0.95 for the two extreme storm surges, with errors of 57.78 cm and 26.55 cm at the highest tide level, respectively. The model's accuracy gradually increases before the delay number reaches the threshold of 24 hours, and gradually decreases after the delay number exceeds the threshold. The temporal duration of the input data also affects the model's accuracy, and longer input data series leads to higher accuracy of the model, but such relationship becomes weak as the temporal duration of the input data exceed a threshold.

Key words: NARX neural network; storm tide elevation; tidal level prediction