

周桑君, 魏笑然, 谢歆哲, 等. 基于长短时记忆神经网络的舟山海域多要素海浪预报模型[J]. 海洋学报, 2024, 46(6): 14–25, doi:10.12284/hyxb2024049

Zhou Sangjun, Wei Xiaoran, Xie Xinzhe, et al. A multivariate wave forecasting model for the Zhoushan archipelago using Long Short-Term Memory deep neural networks[J]. Haiyang Xuebao, 2024, 46(6): 14–25, doi:10.12284/hyxb2024049

基于长短时记忆神经网络的舟山海域 多要素海浪预报模型

周桑君^{1,2}, 魏笑然¹, 谢歆哲^{1,2}, 支泓欢¹, 周一帆¹,
朱正涛³, 李培良^{1,2}, 白晔斐^{1,2*}

(1. 浙江大学海洋学院, 浙江舟山 316021; 2. 浙江大学海南研究院, 海南三亚 572025; 3. 中国空气动力研究与发展中心空天技术研究所, 四川绵阳 621000)

摘要: 本文以 2019 年 1 月 1 日至 2021 年 12 月 31 日舟山群岛南部外海观测点所涵盖的气象、海洋、地形等多种物理量数据为数据基础, 使用长短时记忆 (Long Short Term Memory, LSTM) 神经网络搭建深度学习海浪预报模型, 探讨输入输出序列比和输入要素数量对模型预测性能的影响, 在舟山海域实现波浪三要素, 即有效波高、有效波周期、传播方向的短时预报, 并用 2022 年台风“轩岚诺”和“梅花”期间的数据检验模型对极端海况的预测能力。研究结果表明, 根据实测数据所训练的多要素海浪预报模型具有较好的预测准确度和稳定性, 能较好地实现对极端海况的预测, 当输入输出序列比为 1:1 时模型准确度较高, 预报时长为 1 h 的三要素模型对于日常海况中有效波高、有效波周期和波向的预测均方根误差 (Root Mean Squared Error, RMSE) 分别为 0.116 m、0.569 s 和 24.583°, 对于极端海况中有效波高的预测 RMSE 为 0.191 m, 输入要素数量的增加可进一步提升模型准确度, 但在预测时长较长时也会增加训练成本。

关键词: 深度学习; LSTM; 海浪预报; 舟山

中图分类号: P743.2

文献标志码: A

文章编号: 0253-4193(2024)06-0014-12

1 研究简介

随着可获取的海洋气象数据的增多和机器学习的发展, 多种机器学习技术已广泛应用于海洋领域^[1], 如支持向量机 (Support Vector Machine, SVM)^[2-3]、决策树 (Decision Tree, DT)^[4-5]、人工神经网络 (Artificial Neural Network, ANN)^[6-7] 等。用机器学习方法构建数据模型相对简单, 计算效率更高, 不仅减小了对使用者的水平限制, 还可以节省大量的计算资源^[8]。凭借

优于传统方法或物理模型的多变量处理能力^[9], 神经网络技术发展迅速, 已广泛应用于海浪预测并展现出强大的建模与预测能力^[10-13]。

在众多神经网络模型中, 长短时记忆 (Long Short Term Memory, LSTM) 神经网络^[14] 可有效捕捉序列数据中的长期依赖关系, 因而在海浪预测中应用较多。赵勇等^[15] 基于某岛礁地形模型的波浪演化试验数据, 分别使用 LSTM 神经网络、反向传播 (Back Propagation, BP) 神经网络、SVM 训练能预测畸形波波高的

收稿日期: 2024-02-22; 修订日期: 2024-05-10。

基金项目: 国家自然科学基金项目 (42376212); 浙江大学科研项目资助 (XY2023018)。

作者简介: 周桑君 (1999—), 女, 浙江省东阳市人, 主要从事海洋预报工作。E-mail: 22234117@zju.edu.cn

* 通信作者: 白晔斐 (1980—), 男, 内蒙古自治区呼和浩特市人, 研究员, 博士, 主要从事海洋环境与海洋灾害领域的研究。E-mail: yfbai@zju.edu.cn

模型,在3类模型的预测结果中,LSTM模型的准确度最高。高丽斌^[6]使用时长为两年的第3代浅海海浪数值模式(Simulating WAVes Nearshore, SWAN)的输出结果训练了一种带有卷积LSTM网络层的深度学习模型并在台湾海峡海域进行单要素波高预测,所需运行时间相比传统的数值模式可减少98.59%。Fan等^[17]通过对比6种不同的机器学习方法在有效波高预测任务上的表现,选择了LSTM神经网络与物理模型SWAN结合,构建SWAN-LSTM模型进行单点波高预测,发现该模型准确率比SWAN模型高约65%。Minuzzi和Farina^[18]使用LSTM神经网络实现了对巴西海岸波浪高度的单要素预测,在针对200 m水深海域的6 h有效波高预测中,他们取得了12.96%的平均绝对百分比误差,低于ERA5再分析结果的13.31%。

上述研究表明,LSTM神经网络是进行海浪预报的首选方法,但我们也注意到,多数研究的预测目标以波高为主,而对海上作业同样重要的波周期和波向较少被关注,此外,前人工作的研究区域大多集中在开放大洋,较少涉及中国近岸海域。海浪从远海传播至近岸时易受水深和地形的影响,对近岸海上活动的影响较大且在台风期间更显著,因此,近岸海浪预报对提升近岸港口运输的效率和安全性有重要意义。舟山群岛是我国最大的群岛,其地处东部沿海,岛屿众多,岸线曲折,多深水良港,是多条国际航线的必经之地,位于该海域的宁波舟山港更是我国的重要枢纽港^[19]。以舟山近岸的浮标实测数据为基础的海浪预报更能反映海浪在地形复杂的近岸的传播特点,富有代表性。鉴于上述情况,我们将综合考虑风、浪、流3种影响波浪传播的重要因素,使用LSTM神经网络,针对涵盖了台风信息的多要素单点浮标实测气象水文数据(2019–2021年),构建并训练能预报该站点的未来有效波高、有效波周期及传播方向这3个目标要素的多要素海浪预报模型,同时探讨输入输出序列比和输入要素数量对模型预测性能的影响。该研究能为舟山海域的海浪预报提供技术支持,同时为其他近岸海域的海浪预报工作提供参考。

2 数据与方法

2.1 数据介绍

本研究选取2019年1月1日至2021年12月31日时间段内舟山南部海域一浮标站点的实测气象与水文数据以训练能够预测有效波高、有效波周期、波向的LSTM模型。我们首先对获取的原始数据进行异常值检测和清洗,插值填充单条缺失数据,剔除连

续缺失数据,从而最大程度的保存数据的真实性。经处理获得与风、浪、流相关的共计16项要素数据,其单位、采样间隔、最大值等统计信息如下(表1)。表中波向表示波浪来向,来自正北方的波浪方向被定义为0°,其余方向以此为基准顺时针递增;ADCP流量为声学多普勒流速剖面仪(Acoustic Doppler Current Profilers, ADCP)测得的数据积分后所得。我们将使用该实测数据集训练两套LSTM模型:一套为包括3个输入要素和3个输出要素的三要素模型;另一套为含有7个输入要素和3个输出要素的七要素模型。三要素模型的输入与输出一致,具体包括有效波高、有效周期和主要传播方向;七要素的输入参数通过相关分析筛选得到。

表1 2019–2021年舟山南部海域浮标站各要素信息统计表
(各数据采样间隔均为1 h)

Table 1 Statistical table of each element information of buoy station in the southern waters of Zhoushan from 2019 to 2021, (with a data sampling interval of 1 hour)

观测要素	单位	最大值	平均值	标准差
有效波高	米(m)	7.00	0.98	0.49
有效波周期	秒(s)	15.10	6.00	1.48
波向	度(°)	360.00	113.15	60.46
1 h内最大10 min平均风速	米/秒(m/s)	20.50	6.17	3.07
1 h内最大10 min平均风向	度(°)	360.00	171.29	122.52
分钟内瞬时风速	米/秒(m/s)	25.00	6.58	3.44
分钟内瞬时风向	度(°)	360.00	174.51	123.57
平均波高	米(m)	3.00	0.56	0.25
平均周期	秒(s)	10.6	4.67	0.79
波数	个/千米(km ⁻¹)	325.00	209.48	35.48
谱有效波高	米(m)	7.60	1.18	0.54
谱平均波周期	秒(s)	9.90	4.96	0.85
峰值波周期	秒(s)	24.90	11.35	7.57
峰值能量	焦耳(J)	91.50	0.85	2.40
ADCP流量	立方米/秒(m ³ /s)	41.28	5.16	2.36
流深	米(m)	27.90	25.29	1.11

2.2 数据相关性分析

皮尔逊相关系数可有效度量两组数据间的线性相关程度,多用于剔除与目标要素相关性低的无关要素,删减与目标要素重复度过高的冗余要素,其数学表达式定义为^[20]:

$$\text{Pearson} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (1)$$

其中 n 为样本数量, i 为索引值, x_i, y_i 均为单一变量, \bar{x} 与 \bar{y} 是相应变量的平均值。皮尔逊系数的取值在 $[-1, 1]$ 范围内, 用于刻画 x 与 y 之间的关系度^[21]。相关性强弱的度量标准为: $0.8 \sim 1.0$ 属极度相关, $0.6 \sim 0.8$ 为强相关, $0.4 \sim 0.6$ 为中等程度相关, $0.2 \sim 0.4$ 表示弱相关, $0.0 \sim 0.2$ 则为极弱相关或无相关; 该系数的正负号分别代表两者为正相关或负相关。

从图 1 的皮尔逊相关系数矩阵图中我们发现 1 h 内最大 10 min 平均风向、分钟内瞬时风向、峰值波周期、ADCP 流量、流深(流深 $H = \zeta + d$, 其中 ζ 为海表自由面高度, d 为水深, 海表自由面高度的基准为平均海平面, 主要包含潮汐信息)为无关要素, 平均波高、平均周期、谱有效波高、谱有效波周期为冗余要

素, 1 h 内最大 10 min 平均风速和分钟内瞬时风速两者之间互有重复, 且分钟内瞬时风速与目标要素相关性更高, 因此 1 h 内最大 10 min 平均风速也归为冗余要素。我们希望模型能在不同站点中表现出较好的泛化性能, 所以保留具备测站地理信息的流深要素, 删除其余所有的无关要素、冗余要素, 最终确定七要素模型的输入数据为有效波高、有效波周期、波向、分钟内瞬时风速、波数、峰值能量及流深。图 2 展示了各要素的时间序列, 从中我们可以看到各要素的数值范围差异较大, 变化杂乱, 无浅显规律, 因此本研究利用深度学习技术以分析挖掘不同要素间的复杂联动关系。

2.3 训练方案

鉴于短时预报(12 h 及以下)有助于即时决策和灾害管理, 长时预报(12 h 以上)可为中长期规划提供参考, 本研究在训练方案中共考虑 1 h、3 h、6 h、12 h、18 h、24 h、48 h 7 个预报时长; 同时因现有人工




图 1 16 个气象水文观测要素相关系数矩阵

Fig. 1 The Pearson correlation coefficient matrix among sixteen meteorological-hydrological observation elements




图2 七要素模型中各输入要素的时间序列

Fig. 2 Time series diagram of each input element in the seven-element model

a. 有效波高, b. 有效波周期, c. 波向, d. 分钟内瞬时风速, e. 波数, f. 峰值能量, g. 流深

a. significant wave height, b. significant wave period, c. wave direction, d. instantaneous wind speed per minute, e. wave number, f. peak energy, g. flow depth

智能海浪预报中最佳输入输出时间序列比对模型性能的影响尚不清楚,故额外考虑4种不同比例(1:1、3:1、5:1、7:1)进行试验。两套LSTM模型(三要素模型、七要素模型)均按表2中的28套方案进行训练,再根据评价指标分析预报时长和输入输出序列比对模型预测性能的影响,从而确定最终的海浪预报模型的重要配置参数。本研究中所有训练过程都在Intel(R) Core(TM) i7-8750H CPU @ 2.20GH处理器上

实现。

2.4 评价指标

在本项研究中使用均方根误差(Root Mean Square Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)评估模型预测的准确性,具体定义如下:

$$\text{RMSE} = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - f_i)^2}, \quad (2)$$

表 2 神经网络模型不同输入输出序列比的训练方案表
Table 2 Table of training schemes for neural network models with different input-output sequence ratios

方案编号	输入序列长度/步	比例	输出序列长度(步)/预报时长(h)
M01	1	1 : 1	1
M02	3	3 : 1	
M03	5	5 : 1	
M04	7	7 : 1	
M05	3	1 : 1	3
M06	9	3 : 1	
M07	15	5 : 1	
M08	21	7 : 1	
M09	6	1 : 1	6
M10	18	3 : 1	
M11	30	5 : 1	
M12	42	7 : 1	
M13	12	1 : 1	12
M14	36	3 : 1	
M15	48	5 : 1	
M16	74	7 : 1	
M17	18	1 : 1	18
M18	54	3 : 1	
M19	70	5 : 1	
M20	98	7 : 1	
M21	24	1 : 1	24
M22	72	3 : 1	
M23	120	5 : 1	
M24	168	7 : 1	
M25	48	1 : 1	48
M26	144	3 : 1	
M27	240	5 : 1	
M28	326	7 : 1	

$$\text{MAPE} = 100 \frac{1}{n} \sum_{i=1}^n \frac{|y_i - f_i|}{|y_i|}, \quad (3)$$

其中, y_i 是真实观测值, f_i 是预测值, n 为样本数量, i 为索引值。RMSE 表示预测值与真实值的偏差程度, 数值越小表示预测越准确; MAPE 以百分比表示, 其值越小, 预测越准确。

3 模型框架

3.1 模型结构

本研究以 TensorFlow 框架^[22]和 Keras 框架^[23]为基础, 采用 LSTM 神经网络结构, 开发用于海浪预测的神经网络模型。如图 3 所示, 本研究所使用的神经网络模型结构包括输入层、4 个隐藏层以及输出层。模型的输入层接收形状为 $(N, \text{step_in}, k)$ 的三维时间序列数据, 其中 N 表示训练数据的样本数量, step_in 为每个样本包含的时间步数, k 为每个时间步的要素个数。第一个隐藏层为 LSTM 层, 使用 sigmoid 作为激活函数, 添加 L2 正则化以防止过拟合, 该层用来学习输入数据中的时序依赖关系。第二个隐藏层为 Repeat Vector 层, 为实现对 3 个目标要素的预测, 需将上一个 LSTM 层的输出重复 3 次, 以匹配目标输出序列的形状。第三个隐藏层仍为 LSTM 层, 该层进一步处理在第一个 LSTM 层上学习到的特征信息, 进行最终的多步预测, 并以序列形式返回数据。第四个隐藏层为使用了 Time Distributed 操作的全连接层, 通过保留输入序列的顺序以增强模型的时序预测能力。最后, 根据实际运行的输出序列长度 step_out 设置输出层的形状, 完成模型构建。

3.2 数据集构建

由于该模型的输入同时考虑了处于不同数量级的风、浪、流多个要素, 因此需要通过标准化将所有数据放缩到同一尺度上以稳定模型收敛过程。本研究所采用的标准化方法为:

$$Z = \frac{X - u}{s}, \quad (4)$$

其中, X 为样本, u 为样本的平均值, s 为标准差, Z 为标准化样本。将放缩后的数据集(2019–2021 年)按表 3 划分为用于模型训练的训练集和在模型训练完成后用于指标分析的测试集, 其中训练集内包含了 8 次台风信息, 测试集内没有直接影响该海域的台风数据, 因此再添加 2022 年 9 月台风“轩岚诺”和“梅花”过境时的数据检验模型对极端海况的预测能力。

我们通过滑动窗口将完整数据样本按照时间顺序划分为多个子样本, 构建符合模型训练要求的监督学习数据集, 在划分某一子样本的过程中若遇到时间上缺失的数据段, 将立即停止当前子样本的划分, 并向后移动至缺失数据段之后的新时间点重新开始划分下一条子样本, 其中子样本序列长度由模型的预报时长和输入输出序列比确定。以使用过去 15 h 数据对未来 3 h 海浪要素进行预测的七要素模型为例, 图 4a

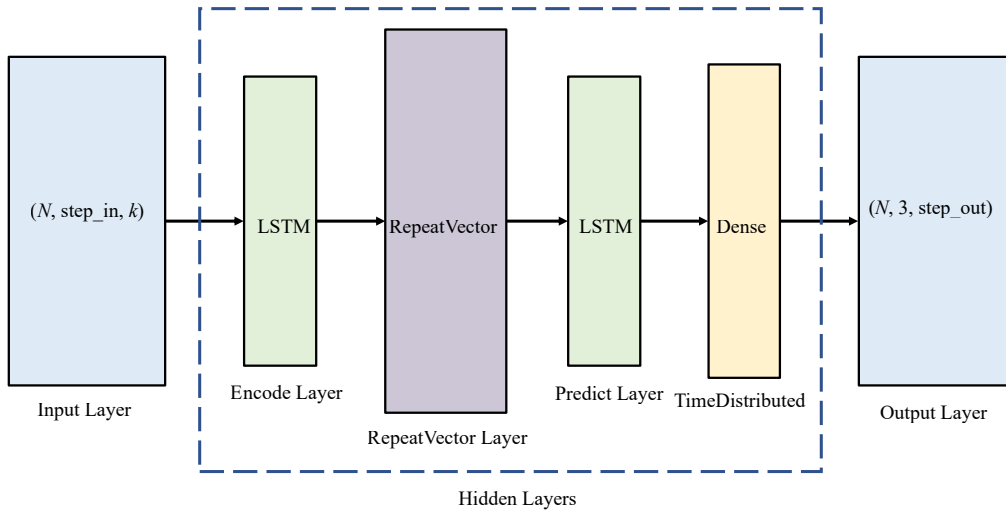


图3 神经网络模型结构

Fig. 3 Structure of the neural network model

表3 数据集划分

Table 3 Dataset segmentation

数据周期	极端海况	名称
2019年1月1日至2021年9月27日	丹娜丝、利马奇、玲玲、米娜、黑格比、美莎克、烟花、灿都	训练集
2021年9月28日至2021年12月31日	无	非极端海况测试集
2022年8月30日至2022年9月30日	轩岚诺、梅花	极端海况测试集

为训练集子样本的划分方式, 图4b为测试集的划分方式。每个子样本由输入序列(深蓝色块)和相应的标注标签(浅蓝色块)组成, 模型将根据大量子样本中的输入序列及其标注的目标序列, 学习输入到输出的映射关系。需要注意的是, 此处的输入包含了7个要素的历史时间序列, 输出包括3个目标要素(有效波高、有效波周期、波向)的预测时间序列。训练集的滑动窗口每次移动步长为1, 以充分学习各要素间的关系, 测试集滑动窗口的移动步长与模型输出序列长度(即预报时长)一致, 以避免输出的预测数据发生重叠, 本例中输出序列长度为3, 因此移动步长也设置为3。

4 结果分析

4.1 模型耗时与误差分析

图5展示了两套模型在28种不同训练方案下的训练耗时, 从图中可知三要素模型与七要素模型受输入输出序列比、预报时长影响的结果大致相同: 训练耗时随着预报时长的增长而增加, 在输入输出序列比为1:1时, 1h三要素模型的训练耗时为8min, 48h三要素模型的耗时为32min; 训练耗时也随着输入输出序列比例的增大而增加, 且在长时预报中(12h以

上)的增长幅度更大, 1h七要素模型在1:1和7:1设定下的耗时为8min、12min, 48h七要素模型的耗时则分别为52min、318min。此外我们也发现, 七要素模型的耗时在短时预报(预报时长为12h及以下)任务中低于三要素模型, 而在长时预报中高于三要素模型。整体而言训练耗时主要由单次数据量决定, 输入输出序列比越大、预报时长越长, 对应的数据量越多, 训练耗时也随之增加。短时预报中七要素模型的耗时少于三要素模型则是因为在数据量增长不多的前提下增加的输入要素提供了更丰富的信息, 利于模型学习其中规律, 从而加速了训练过程。

我们在非极端海况的测试集上详细评估不同训练方案下的模型, 表4给出了经反归一化后的结果与真实值的RMSE, 需要注意的是, 采集到的原始数据为两位小数, 而模型的预测值在数据精度上则具有更大的灵活性, 为了更细致地区分不同模型间的性能差异, 我们将模型预测结果及其误差值精确到了3位小数。表中显示, 随着预测时长从1h增加到48h, RMSE也随之增加, 有效波高从0.11m升至0.38m, 有效波周期从0.56s升至1.25s, 波向从24.00°增至58.00°; 输入输出序列比对RMSE影响不大, 相同预报时长、不同序列比例设定下的RMSE差值在0.006m、0.016s、




图 4 使用 15 h 历史数据预测未来 3 h 海浪的模型子样本划分

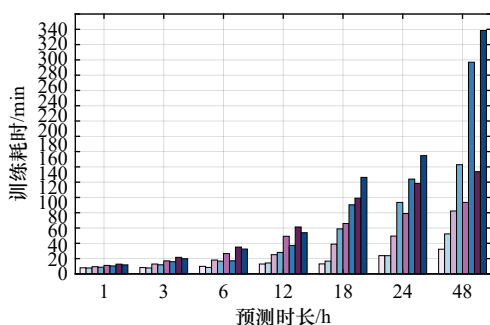
Fig. 4 Model subsample partitioning for predicting waves in the next 3 hours using 15 hours of historical data

a. 训练集子样本划分, b. 测试集子样本划分

a. Training set subsample division, b. test set subsample division

1.148°左右浮动;引入更多相关要素能在一定程度上

提高模型预测精度,如输入输出序列比为 1 : 1、预报时长 6 h 时,七要素模型的 3 项 RMSE 为 0.174 m、0.818 s、44.824°, 低于三要素模型的 0.181 m、0.850 s、45.581°。此外我们也探索了七要素模型与不包含“流深”的六要素模型在预测误差上的差异,由于我们文中仅在舟山南部站点进行验证,而同一站点的流深变化不大,因此两类模型差距并不明显。



- 三要素模型 输入:输出 = 1 : 1
- 三要素模型 输入:输出 = 3 : 1
- 三要素模型 输入:输出 = 5 : 1
- 三要素模型 输入:输出 = 7 : 1
- 七要素模型 输入:输出 = 1 : 1
- 七要素模型 输入:输出 = 3 : 1
- 七要素模型 输入:输出 = 5 : 1
- 七要素模型 输入:输出 = 7 : 1

图 5 所有模型训练耗时

Fig. 5 Time consuming for all model training

4.2 非极端海况期间模型验证

图 6 以时间序列形式展示了三要素模型在设定输入输出序列比为 1 : 1、预报时长分别为 1 h、6 h、18 h、48 h 下对非极端海况测试集(表 3)中三目标要素的预测效果。该测试时间段内的波浪变化相对和缓,有效波高在 10 月 11 日前后出现受南海台风“圆规”影响而产生的大浪过程外,波高均低于 2 m。通

表 4 两类模型的 RMSE 对比
Table 4 RMSE comparison of two types of models

方案编号	预报时长/h	比例	有效波高/m		有效波周期/s		波向/(°)	
			三要素	七要素	三要素	七要素	三要素	七要素
M01	1	1 : 1	0.116	0.116	0.569	0.564	24.583	24.296
M02		3 : 1	0.116	0.113	0.561	0.548	24.875	24.571
M03		5 : 1	0.114	0.112	0.564	0.548	24.568	24.882
M04		7 : 1	0.114	0.114	0.566	0.550	24.975	24.746
M05	3	1 : 1	0.149	0.146	0.704	0.678	31.565	32.424
M06		3 : 1	0.150	0.147	0.701	0.678	32.409	32.086
M07		5 : 1	0.149	0.147	0.702	0.676	32.861	33.492
M08		7 : 1	0.149	0.147	0.699	0.680	32.682	32.526
M09	6	1 : 1	0.181	0.174	0.850	0.818	45.581	44.824
M10		3 : 1	0.187	0.173	0.846	0.811	47.467	44.643
M11		5 : 1	0.186	0.173	0.836	0.816	48.320	45.477
M12		7 : 1	0.182	0.173	0.830	0.818	47.837	45.824
M13	12	1 : 1	0.232	0.223	0.954	0.943	48.260	46.127
M14		3 : 1	0.231	0.224	0.944	0.938	47.521	46.212
M15		5 : 1	0.236	0.230	0.945	0.951	48.184	47.818
M16		7 : 1	0.235	0.219	0.941	0.938	47.982	49.797
M17	18	1 : 1	0.255	0.244	1.022	1.020	50.168	51.799
M18		3 : 1	0.257	0.254	1.007	1.005	49.488	50.330
M19		5 : 1	0.258	0.253	1.001	1.005	49.442	51.580
M20		7 : 1	0.264	0.260	1.010	1.026	51.358	50.763
M21	24	1 : 1	0.295	0.296	1.107	1.120	54.430	50.218
M22		3 : 1	0.308	0.294	1.105	1.077	55.247	52.649
M23		5 : 1	0.302	0.303	1.085	1.078	54.854	52.503
M24		7 : 1	0.292	0.300	1.095	1.080	53.823	52.248
M25	48	1 : 1	0.372	0.366	1.218	1.218	58.143	53.154
M26		3 : 1	0.381	0.373	1.208	1.170	57.361	53.212
M27		5 : 1	0.408	0.389	1.284	1.241	58.145	54.375
M28		7 : 1	0.388	0.362	1.258	1.278	57.736	54.693

过与实测数据对比我们发现当预报时长较短时(低于 12 h), 三要素模型可有效追踪波浪在波高、周期、波向上的演化过程, 其中 1 h 模型在三目标要素的 RMSE 值仅为 0.117 m、0.563 s、24.861°, 而计算所需的时间仅为 0.091 s; 然而当预报时长较长时(高于 12 h), 三要素模型重构出的时间序列出现振幅衰减、位相滞后、精度降低等现象, 48 h 模型的误差增长至 0.372 m、1.218 s、58.143°。

4.3 极端海况期间模型验证

图 7 展示了输入输出序列比为 1 : 1, 预报时长分别为 1 h、3 h、6 h 和 12 h 的三要素模型对台风“轩岚诺”(2022 年 9 月 1 日至 6 日)、“梅花”(2022 年 9 月 12 日至 15 日)过境前后的 3 个目标要素的预测结果。图中蓝色阴影表示受台风影响的时间段, 红色阴影为出现 3 m 以上海浪的时间段。测站记录显示, “轩岚诺”期间有效波高从 1 m 逐渐增至 4 m, 有效波

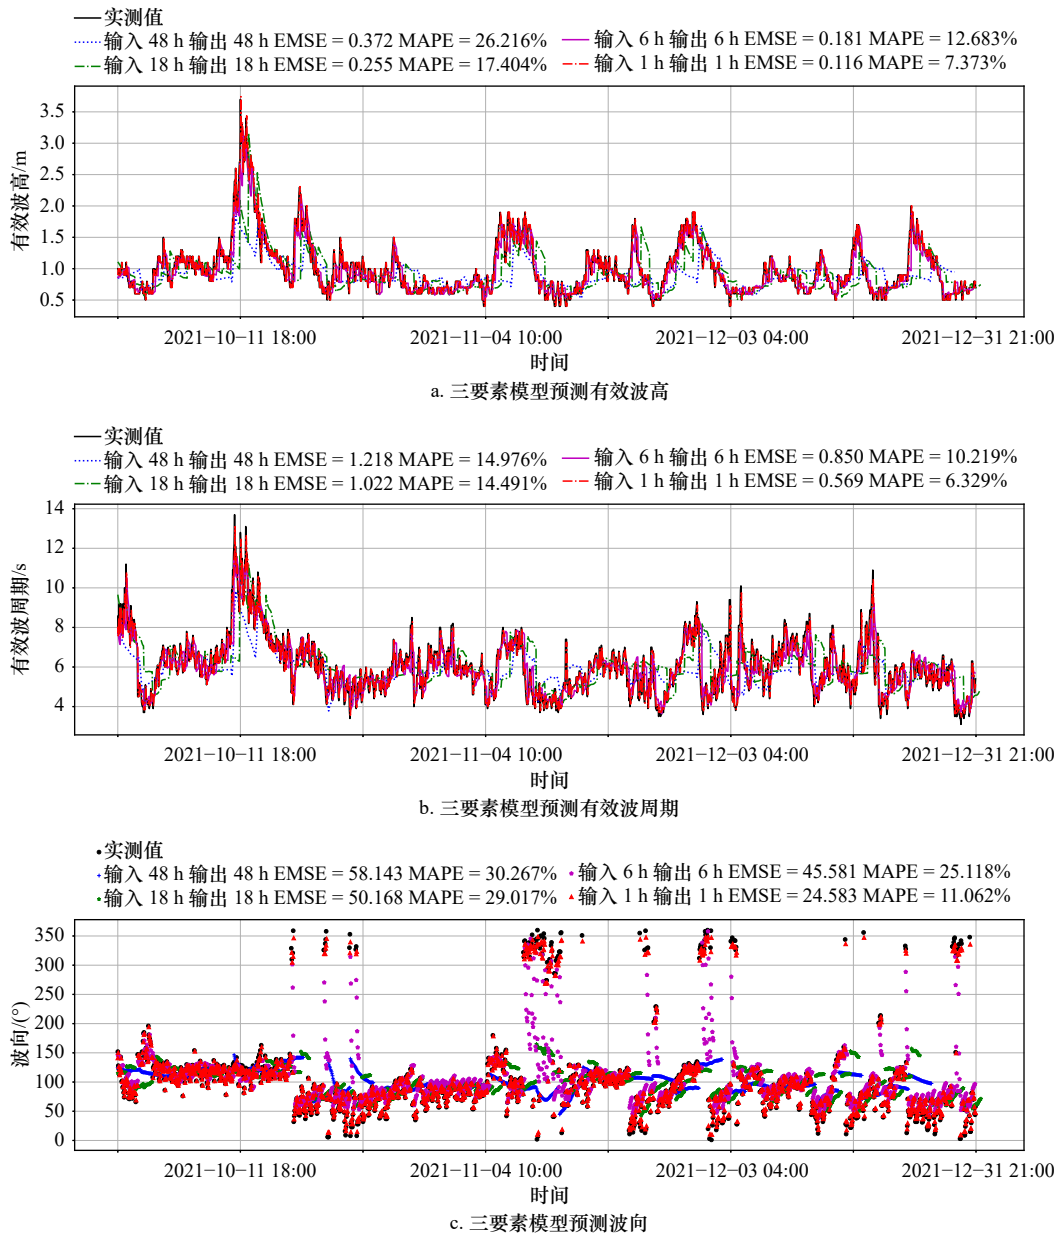


图 6 三要素海浪预报模型在非极端海况期间的预测结果与实测值的对比验证

Fig. 6 The comparison between the predicted results of the three-element wave prediction model and the measured values during non-extreme sea conditions

周期最大达 10.10 s。“轩岚诺”过后波浪运动趋向和缓,有效波高低于 1 m,有效波周期下降至 5 s 左右。受“梅花”影响,自 9 月 12 日起该测点海域有效波高急速攀升至 7 m,并随着台风中心的快速北移而快速下降至 1 m,此期间波周期又抬升至 10 s 左右。这两个台风过程使得局地风场变得异常复杂,同时台风浪中涌浪和风浪此消彼长、相互影响,导致波向呈现出频繁且不定变换,进而增加了模型预测的难度。对比实测数据可知,三要素模型在极端海况期间仍能在 0.06 s 内较好地预测台风浪的演化过程,1 h 模型在三目标要素的 RMSE 值为 0.191 m、0.636 s、91.976°。

该误差随预报时长的增加而增大,12 h 模型的 RMSE 为 0.448 m、0.834 s、94.630°。“轩岚诺”期间 4 种不同预报时长模型的预测基本合理,但在“梅花”期间 12 h 模型表现不佳。

5 结论

本文基于 LSTM 神经网络结构,利用舟山南部外海单观测站点的多要素实测气象与水文数据搭建并训练了深度学习海浪预报模型,探讨了输入序列与输出序列的比例、输入要素的数量对模型性能的影响,实现了对该站点未来有效波高、有效波周期及波向

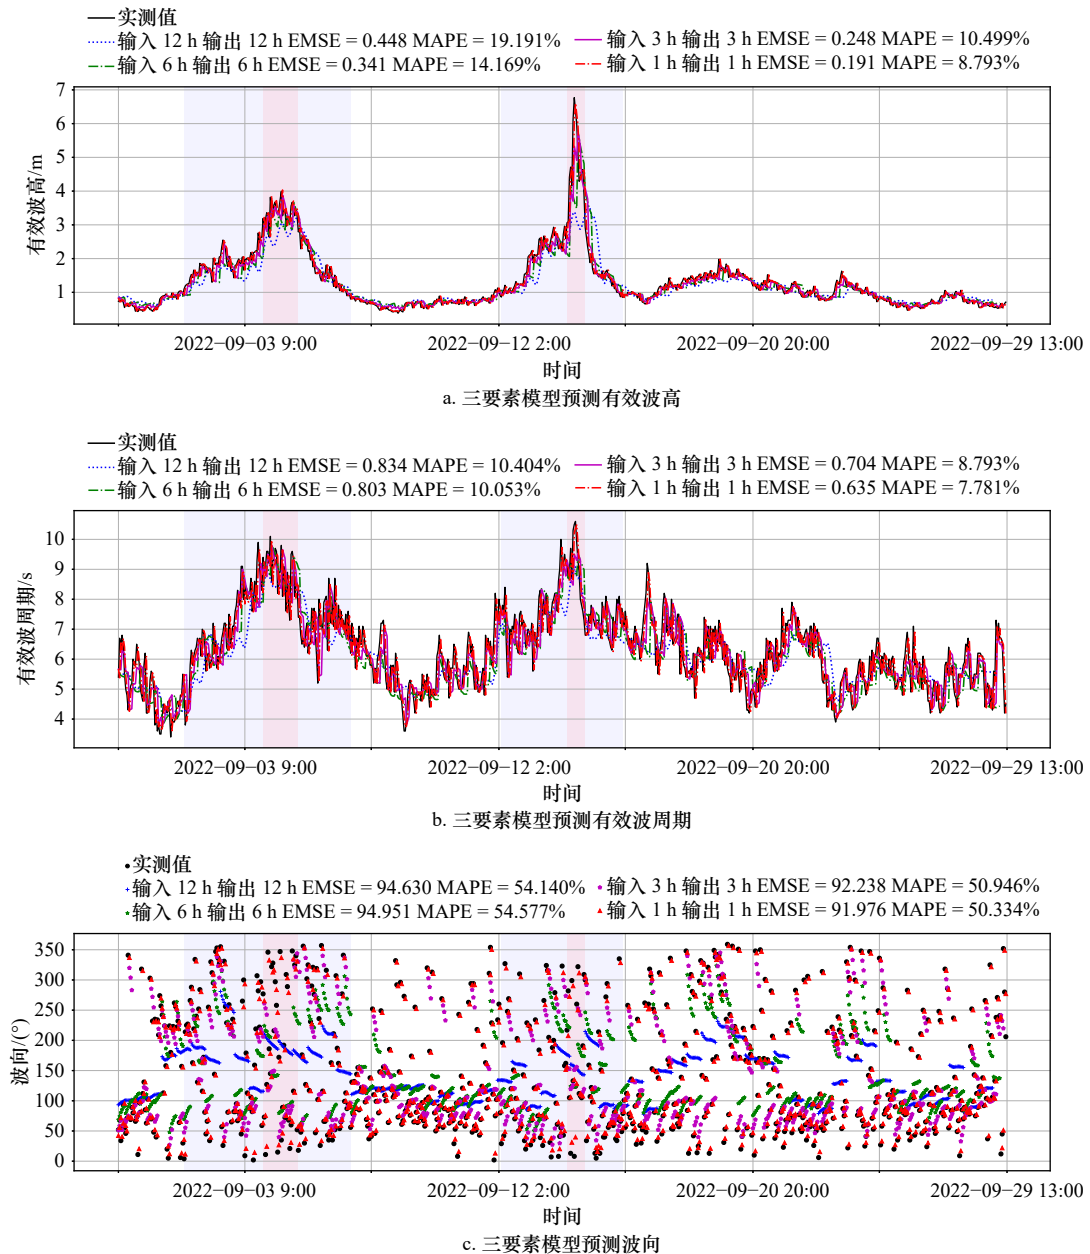


图7 三要素海浪预报模型在台风“轩岚诺”与“梅花”期间的预测结果与实测值的对比验证

Fig. 7 The comparison between the predicted results of the three-element wave forecast model during Typhoon “Hinnamnorr” and “Muifa” and the measured values

的多要素海浪预报,并评估了多要素海浪预报模型在非极端海况和极端海况下的预报能力,具体结论如下:

(1)短时预报(12 h及以下)模型能准确预报观测站附近海域的海浪状况,预测误差随着预报时长的增加而增加。输入输出序列比为1:1时,预报时长为1 h、3 h、6 h、12 h三要素模型的有效波高RMSE为0.116 m、0.149 m、0.181 m、0.232 m,有效波周期RMSE为0.569 s、0.704 s、0.850 s、0.954 s,波向RMSE为24.583°、31.565°、45.581°、48.260°。

(2)不同设定下的模型训练耗时在10 min至320 min不等,总体趋势为输入输出序列比越大、预报时长越长,模型训练耗时越长。

(3)增大输入输出序列比对模型预报准确度影响不大,相同预报时长、不同序列比例设定下的RMSE差异在0.006 m、0.016 s、1.148°左右浮动。

(4)输入要素数量的增加对模型准确度的提升并不显著,且在进行长时预报时(12 h以上)训练时间会大幅提高。输入输出序列比为1:1、预报时长48 h时,三要素模型的有效波高RMSE和训练耗时分别

为 0.372 m、32 min, 七要素模型则为 0.367 m、52 min。

(5) 尽管训练集中台风数量不多, 但短时预报模型仍能较好地预测台风期间的有效波高和波周期, 输入输出序列比为 1 : 1 时 1 h 三要素模型在有效波高

和波周期的 RMSE 值为 0.191 m、0.636 s。

综合考虑时间成本及数据可获得性, 本研究推荐使用输入输出序列比为 1 : 1 的短时预报三要素模型作为最终的海浪预报模型。

参考文献:

- [1] Qin Yue, Su Changyu, Chu Dongdong, et al. A review of application of machine learning in storm surge problems[J]. *Journal of Marine Science and Engineering*, 2023, 11(9): 1729.
- [2] Mahjoobi J, Mosabbe E A. Prediction of significant wave height using regressive support vector machines[J]. *Ocean Engineering*, 2009, 36(5): 339–347.
- [3] 王燕, 钟建, 张志远. 支持向量回归的机器学习方法在海浪预测中的应用 [J]. *海洋预报*, 2020, 37(3): 29–34.
Wang Yan, Zhong Jian, Zhang Zhiyuan. Application of support vector regression in significant wave height forecasting[J]. *Marine Forecasts*, 2020, 37(3): 29–34.
- [4] Mahjoobi J, Etemad-Shahidi A. An alternative approach for the prediction of significant wave heights based on classification and regression trees[J]. *Applied Ocean Research*, 2008, 30(3): 172–177.
- [5] Ellenson A, Pei Yuanli, Wilson G, et al. An application of a machine learning algorithm to determine and describe error patterns within wave model output[J]. *Coastal Engineering*, 2020, 157: 103595.
- [6] Hu R, Fang F, Pain C C, et al. Rapid spatio-temporal flood prediction and uncertainty quantification using a deep learning method[J]. *Journal of Hydrology*, 2019, 575: 911–920.
- [7] 石绥祥, 王蕾, 余璇, 等. 长短期记忆神经网络在叶绿素 *a* 浓度预测中的应用 [J]. *海洋学报*, 2020, 42(2): 134–142.
Shi Suixiang, Wang Lei, Yu Xuan, et al. Application of long term and short term memory neural network in prediction of chlorophyll *a* concentration[J]. *Haiyang Xuebao*, 2020, 42(2): 134–142.
- [8] Jain P, Deo M C. Real-time wave forecasts off the western Indian coast[J]. *Applied Ocean Research*, 2007, 29(1/2): 72–79.
- [9] Gu Chengcheng, Li Hua. Review on deep learning research and applications in wind and wave energy[J]. *Energies*, 2022, 15(4): 1510.
- [10] Deo M C, Jha A, Chaphekar A S, et al. Neural networks for wave forecasting[J]. *Ocean Engineering*, 2001, 28(7): 889–898.
- [11] Peres D J, Iuppa C, Cavallaro L, et al. Significant wave height record extension by neural networks and reanalysis wind data[J]. *Ocean Modelling*, 2015, 94: 128–140.
- [12] James S C, Zhang Yushan, O'Donncha F. A machine learning framework to forecast wave conditions[J]. *Coastal Engineering*, 2018, 137: 1–10.
- [13] Law Y Z, Santo H, Lim K Y, et al. Deterministic wave prediction for unidirectional sea-states in real-time using artificial neural network[J]. *Ocean Engineering*, 2020, 195: 106722.
- [14] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.
- [15] 赵勇, 苏丹, 邹丽, 等. 基于 LSTM 神经网络的畸形波预测 [J]. *华中科技大学学报 (自然科学版)*, 2020, 48(7): 47–51.
Zhao Yong, Su Dan, Zou Li, et al. Rogue wave prediction based on LSTM neural network[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2020, 48(7): 47–51.
- [16] 高丽斌. 基于深度学习的台湾海峡及周边海域波浪预报研究 [D]. 福州: 福建农林大学, 2019.
Gao Libin. Wave forecasting of Taiwan Strait and its surrounding waters based on deep learning[D]. Fuzhou: Fujian Agriculture and Forestry University, 2019.
- [17] Fan Shuntao, Xiao Nianhao, Dong Sheng. A novel model to predict significant wave height based on long short-term memory network[J]. *Ocean Engineering*, 2020, 205: 107298.
- [18] Minuzzi F C, Farina L. A deep learning approach to predict significant wave height using long short-term memory[J]. *Ocean Modelling*, 2023, 181: 102151.
- [19] 王军, 王国欣. 宁波舟山港沿海航道保护范围研究与探讨 [J]. *中国水运*, 2020(4): 51–53.
Wang Jun, Wang Guoxin. Research and discussion on the protection scope of coastal navigation channels in Ningbo Zhoushan Port[J]. *China Water Transport*, 2020(4): 51–53.
- [20] Xu Honghui, Deng Yong. Dependent evidence combination based on shearman coefficient and pearson coefficient[J]. *IEEE Access*, 2018, 6: 11634–11640.
- [21] Jebli I, Belouadha FZ, Kabbaj M I, et al. Prediction of solar energy guided by pearson correlation using machine learning[J]. *Energy*, 2021, 224: 120109.
- [22] Abadi M, Barham P, Chen Jianmin, et al. TensorFlow: a system for large-scale machine learning[C]//Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation. Savannah: USENIX Association, 2016: 265–283.
- [23] Ketkar N. Introduction to keras[M]//Ketkar N. Deep Learning with Python: A Hands-on Introduction. Berkeley: Apress, 2017: 97–111.

A multivariate wave forecasting model for the Zhoushan archipelago using Long Short-Term Memory deep neural networks

Zhou Sangjun^{1,2}, Wei Xiaoran¹, Xie Xinzhe^{1,2}, Zhi Honghuan¹, Zhou Yifan¹,
Zhu Zhengtao³, Li Peiliang^{1,2}, Bai Yefei^{1,2}

(1. Ocean College, Zhejiang University, Zhoushan 316021, China; 2. Hainan Institute of Zhejiang University, Zhejiang University, Sanya 572025, China; 3. Institute of Space Technology, China Aerodynamics Research and Development Center, Mianyang 621000, China)

Abstract: This study is based on the meteorological, oceanic, terrain and other physical quantity data covered by the observation points in the southern Zhoushan Islands from January 1, 2019 to December 31, 2021, and uses long short-term memory neural network (LSTM) to build deep learning wave forecast model. We explore the impact of the input-output sequence ratio and the number of input elements on the prediction performance of the model, realize the short-term forecast of the three elements of waves in the Zhoushan sea area, that is the significant wave height, the significant wave period and the propagation direction, and use the data during the 2022 typhoons “Hinnamnor” and “Muifa” to test the model’s prediction ability for extreme sea conditions. The research results show that the multi-element deep learning wave forecast model trained based on measured data has good prediction accuracy and stability, and can realize the prediction of extreme sea conditions. When the input-output sequence ratio is 1 : 1, the model accuracy is higher. In non-extreme sea conditions, the three-element model with a prediction time of 1 hour accurately predicts significant wave height, significant wave period and direction, with Root Mean Squared Errors (RMSE) of 0.116 m, 0.569 s, and 24.583° respectively. In extreme sea conditions, the prediction RMSE for the significant wave height is 0.191 m. The increase in the number of input elements can further improve the model accuracy but also increase the training cost when the prediction time is long.

Key words: deep learning; Long Short-Term Memory model; wave forecasting; Zhoushan