

文章编号: 1007-7294(2024)06-0832-11

考虑时间相关性的风速和波浪高度短期预测

姚 骥^{1,2,3}, 汪雪良^{1,2}, 武文华³, 顾学康^{1,2}, 张欣玉^{1,2}

(1. 中国船舶科学研究中心, 江苏 无锡 214082; 2. 深海技术科学太湖实验室, 江苏 无锡 214082;

3. 大连理工大学 运载工程与力学学部, 辽宁 大连 116024)

摘要: 风与波浪高度是海洋工程设计的重要参数之一, 其准确预测具有重要的工程意义。针对波浪高度复杂多变、难以预测的挑战, 本文考虑时间相关性, 利用长短时记忆(Long-Short-Term Memory, LSTM)神经网络方法建立风和波浪高度的短期预测模型。首先, 对波浪高度和风速等海洋环境原始时间序列进行分析, 并选取不同时间间隔对浪高和风速极值进行取值; 其次, 对风速与波浪高度开展相关性分析, 并基于LSTM方法, 构建风和波浪高度单步预测模型。在时间间隔为0.5 h时, 波浪的预测误差为0.12 m; 进而构建风和波浪联合预测模型, 预测风速下的波高预测误差仅为0.12 m, 与实测风速下的波浪预测误差基本一致。

关键词: 相关性分析; 长短时记忆神经网络; 风速预测; 波浪预测; 联合预测模型

中图分类号: P751 文献标识码: A doi: 10.3969/j.issn.1007-7294.2024.06.003

Short-term forecast of wind speed and wave height considering time correlation

YAO Ji^{1,2,3}, WANG Xue-liang^{1,2}, WU Wen-hua³, GU Xue-kang^{1,2}, ZHANG Xin-yu^{1,2}

(1. China Ship Science Research Center, Wuxi 214082, China; 2. Taihu Laboratory of Deepsea

Technological Science, Wuxi 214082, China; 3. Faculty of Vehicle Engineering and

Mechanics, Dalian University of Technology, Dalian 116024, China)

Abstract: As wind speed and wave height are the main loading parameters in offshore facility operations, their accurate prediction is of great importance. In order to solve the problem of wind speed and wave height prediction with complex and changeable characteristics, a wave height forecast model was established based on prototype monitoring data and Long-Short-Term Memory (LSTM) neural network. Firstly, the correlation analysis of wind speed and wave height was carried out based on prototype monitoring data. Then, a one-step-ahead wind speed forecast model and wave height forecast method were established based on LSTM neural network. Different prediction models with different time intervals ($t=0.5$ h, 1 h, 3 h) were built to verify the accuracy. Finally, a joint prediction model based on two forecast models was obtained with a prediction error of only 0.12 m at the time interval of 0.5 h.

Key words: correlation analysis; LSTM; wind speed forecast; wave height forecast; joint prediction model

收稿日期: 2023-11-21

基金项目: 国家重点研发计划项目(2021YFC2802300); 江苏省卓越博士后计划项目(2023ZB629)

作者简介: 姚 骥(1994-), 男, 博士, 工程师, 通讯作者, E-mail: yj_dllut@163.com;

汪雪良(1977-), 男, 博士, 研究员。

0 引 言

风和波浪是海洋结构设计重要的环境参数。在恶劣海况下,平台浮体将产生大幅运动,对浮体的结构安全产生巨大威胁。因此,开展风和波浪的载荷要素分析及预测可以有效评估平台人员的作业安全,避免风险。然而,海洋环境的强非线性特征给风和波浪的短期预测带来挑战。

传统数值方法对于波浪的分析预测通常采用数值模型为主,许多学者基于物理模型^[1-2]对波浪的变化模式进行分析,提出了SWAN模型^[3-5]、WAM模型^[6-9]、Wave Watch III模型^[10-11]及JONSWAP模型^[12]。Ou等^[13]利用SWAN模型对我国台湾岛周围沿海水域的台风下波浪预测问题进行了研究;Rogers等^[14]开展了基于SWAN模型的波浪预测模型的影响因素研究,发现大气环境占主导因素;Mentaschi等^[15]利用Wave Watch III模型对西班牙地中海沿岸波浪信息进行了研究;Kalourazi等^[16]利用Wave Watch III模型建立了墨西哥湾飓风下波浪预测模型,并与飓风Ivan过境期间的现场观测结果进行对比,获得了较为准确的模型分析结果;付睿丽^[17]基于波群分别建立不同水深极端波浪的短期预报方法并取得较高精度;王煥^[18]基于多正弦函数分解(MSFD)模型开展了南海月平均有效波高的预测研究。虽然随着数值求解方法的不断进步,各数值模型的计算成本不断降低,但由于其自身存在简化等不足,使得各数值模型的泛化性能及准确率无法满足实际工程需求。同时,影响风场与波浪的环境要素众多,诸如温度、气压、湿度等因素均对风场及波浪产生影响。同时风场与波浪之间也存在一定相关性,因此,目前基于有限测量数据建立波浪预测模型仍是需要解决的科研难题。

随着机器学习方法的不断发展,许多学者利用数据驱动的方法开展波浪预测问题研究。Deo等^[19]利用人工神经网络的方法建立了波高预测模型;Mandal等^[20]利用循环神经网络的方法建立了波高预测模型,并发现其预测结果要优于人工神经网络模型;Mahjoobi等^[21]利用支持向量机方法预测了波浪高度,结果显示支持向量机模型预测精度较为准确且计算成本小于人工神经网络模型;Demetris等^[22]利用监督学习分类算法对波浪高度进行了预测研究,利用实测数据对沿岸波浪高度进行了分类研究并取得了较高的准确度;Alexander等^[23]基于遗传算法给出了波浪数据缺失重构算法;黄心裕^[24]等基于Prophet算法建立了海南近海波浪长时段时序预测模型;郝伟等^[25]针对海浪有义波高统计预测问题,针对AR模型、ANN模型与LSTM模型等典型预报方法开展了对比分析研究。但是,当前研究大多是针对日常海况下波浪高度的预测,预测模型在极端海况下的泛化性能研究较少。此外,当前基于数据驱动的波浪预测模型均需要同时考虑气压、温度、海拔高度等多种因素,应用条件较为苛刻,在实际工程中应用存在不足。

本文针对风和波浪复杂性带来的难以预测等问题,提出一种基于数据驱动的风速和波高深度学习预测模型。首先,对南海实测风场与波浪高度开展分析,对其时间相关性及迟滞效应开展研究;其次,利用长短时记忆(Long-Short-Term Memory, LSTM)神经网络,建立风速与波浪高度单步预测模型;进而,建立风速与波浪高度联合预测模型。

1 实测风速与波高数据分析

1.1 海洋环境监测系统

LH11-1油田的半潜式生产平台(NHTZ Floating Production System, FPS)位于中国南海,距离香港215 km,工作水深260~305 m。自2010年起,大连理工大学在NHTZ FPS建立了现场监测系统(图1),开展了海洋环境载荷要素、浮体运动响应和系泊系统力学性能的监测。其中海洋环境监测子系统主要测量风参数(风速、风向)、海流参数(流速、流向)和波浪参数(波高、波浪周期和波浪压力)。表1给出了海洋环境监测系统监测信息及采集参数^[26]。

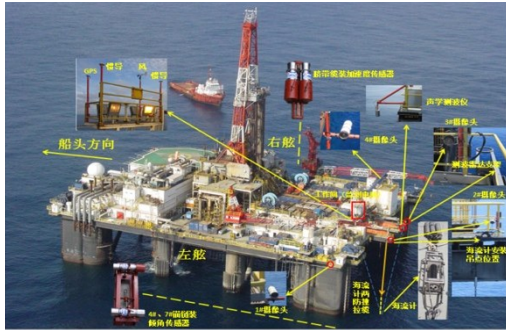


图1 海洋环境监测系统

Fig.1 Meta-ocean environmental loading monitoring system

表1 海洋环境监测信息
Tab.1 Meta-ocean environmental loading monitoring information

海洋环境	监测信息	采样频率
风	风速、风向	1 Hz
波浪	波高、周期	1分钟1组
	压力	2 Hz
海流	流速、流向	10分钟1组

1.2 实测风速和波高相关性分析

风和波浪是影响海洋平台安全服役的重要海洋环境因素。当今,对于风和波浪的预测仅停留在对于海况等级的预报,对于风速及浪高的精准预测研究较少。同时,由海况等级划分表可以看出,波浪高度与风速存在较强相关性。因此,采用互协方差分析其相关性:

$$COV_{X,Y} = E\left((X - E(X))(Y - E(Y))^T\right) \tag{1}$$

式中,X、Y分别为风速和波浪高度。

图2给出了2014年1月至2月期间工作海况下不同时间段内(随机选取4周)风速与风速、风速与浪高及浪高与浪高的相关性曲线。可以看出,对于南海风场,风速存在较强的时间相关性,其相关性最大值发生在约1天左右。波高也存在着较强的时间相关性,其时间相关性最大值发生在1至2天。同时,风速与浪高之间存在较强的滞后效应。其时间相关性最大值发生在6~12小时左右。因此,在风场预测模型及波浪高度预测模型建立过程中,应充分考虑时间相关性。

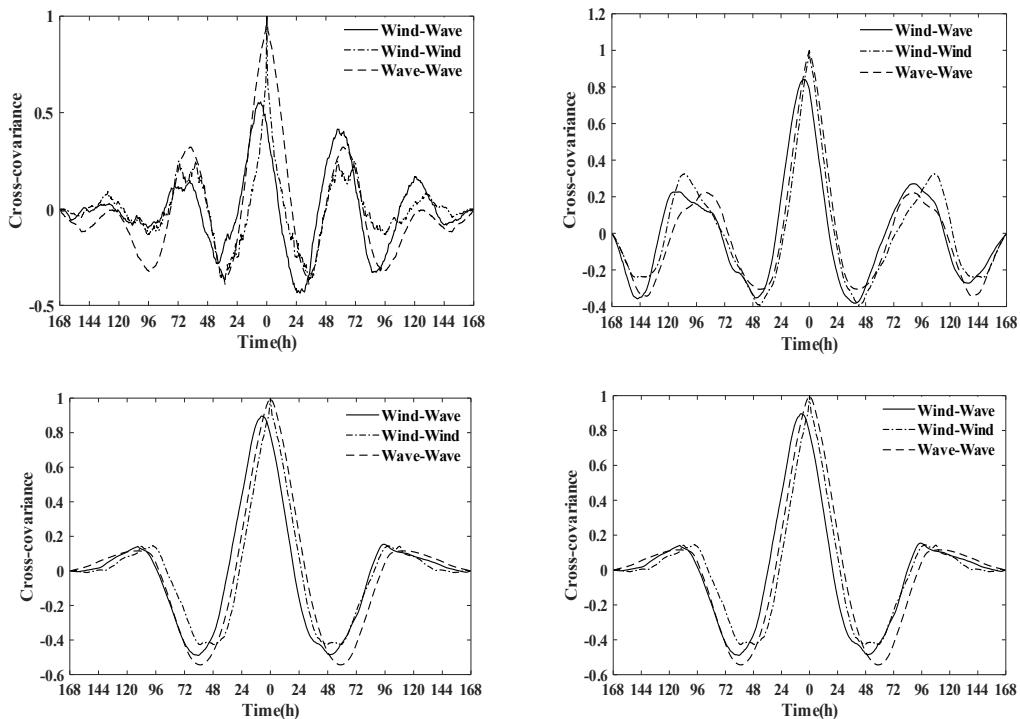


图2 工作海况下不同时期风速与浪高的互相关曲线

Fig.2 Cross-correlation relationship of wind speed and wave height at different periods under stable sea conditions

同时,对台风等恶劣海况下的风速与波高相关性开展分析。选取超强台风“天兔”过境期间数据进行研究。图3给出了台风“天兔”期间风速与浪高的互相关曲线。可以看出,在超强台风“天兔”等极端海况下,浪高与风速之间同样存在较强的滞后特性,为所建模型在极端海况下的应用打下了基础。

1.3 实测风速和波高数据特征提取

选取2013年12月至2014年3月期间监测数据作为训练集,选取2014年4月数据作为测试集。表2给出了监测数据的统计信息,可以看出,所选训练集最大风速达到19.70 m/s,最大波浪高度达到5.20 m;所选测试集最大风速达到18.70 m/s,最大波高达到5.88 m。表明了所选实测数据集涵盖了从平稳海况到恶劣海况等较为完备的海洋信息。

表2 所选监测数据统计信息

Tab.2 Statistic information of the monitoring data

	监测时间	最大风速/(m·s ⁻¹)	平均风速/(m·s ⁻¹)	最大浪高/m	平均浪高/m
训练集	2013.12~2014.03	19.70	4.71	5.20	1.21
测试集	2014.04	18.70	3.89	5.88	1.32

选取不同时间间隔 τ 将风速及浪高实测数据 $x(t)$ 划分成子序列 $x_i(k), k=1,2,\dots$ 。将各子序列 $x_i(k)$ 的极大值作为该时间段内的特征参数:

$$(x_i)_{\max} = \max(x_i(k)), i = 1, 2, \dots, n \tag{2}$$

图4给出了不同时间间隔 τ 下的风速极值(Wind Speed Extreme Value, WSEV)及浪高极值(Wave Height Extreme Value, WHEV)选取示意图,其中红点表示该时间段内的极值参数。

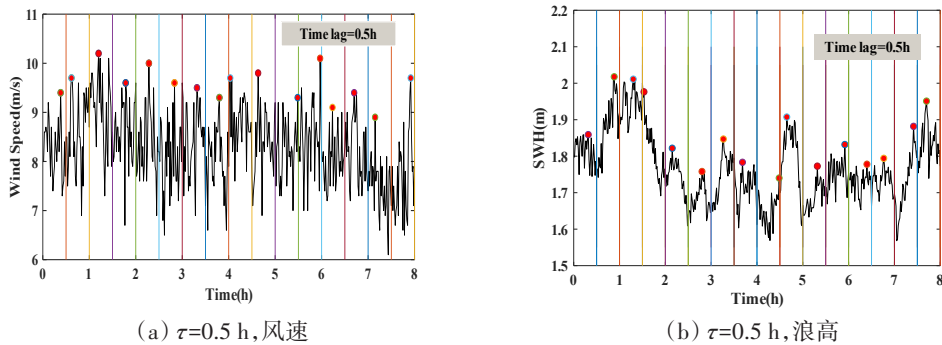


图4 不同时间间隔 τ 下风速及波浪高度极值参数选取示意图

Fig.4 Schematic diagram of WSEV and WHEV selection

2 基于数据驱动的风速深度学习预测模型

2.1 长短时记忆神经网络 (Long-Short Term Memory Network, LSTM)

与标准神经网络相比,循环神经网络是以序列数据为输入、在序列演进方向进行递归且所有节点按链式连接的递归神经网络。可将上一个状态的信息传递到当前状态,当输出为时间序列时,可以将其展开为一系列相互连接的标准神经元。LSTM神经网络是循环神经网络的一种,用以解决一般循环神经网络中存在的长期依赖问题。

LSTM神经网络结构由Hohreiter和Schmidhuber^[27]于1997年提出,是一种特殊的循环神经网络,由




图3 台风“天兔”过境期间风速与浪高互相关曲线

Fig.3 Cross-correlation relationship of wind speed and wave height during Typhoon Usagi

一系列 LSTM 元组成,如图 5 所示。

如图 6 所示, LSTM 元包括新输入 x_t 、输出 h_t 、输入门 i_t 、忘记门 f_t 、输出门 o_t 。引入输入门 i_t 、忘记门 f_t 与输出门 o_t 的目的是控制每一步输出的值,使得误差在该神经元传递过程中保持不变。LSTM 是循环神经网络的一个特例,新输入和每个门都会将前一次的输出 h_{t-1} 作为本次输入的一部分,因此新输入 x_t 、输入门 i_t 、忘记门 f_t 、输出门 o_t 的输入都是由 $[x_t, h_{t-1}]$ 二元组构成。

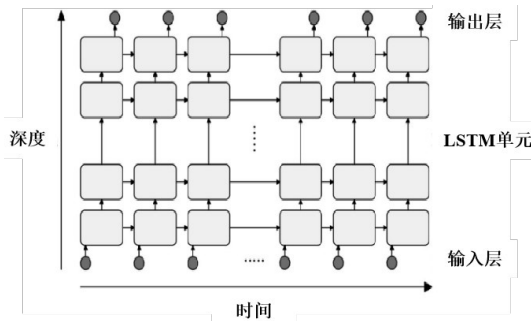


图 5 LSTM 结构

Fig.5 LSTM structure




图 6 LSTM 循环体结构

Fig.6 LSTM loop-unit structure

新输入 $[x_t, h_{t-1}]$ 经过激活函数 σ_c 作用后,得到记忆元的候选值 C_t ,

$$C_t = \sigma_c(W_c[x_t, h_{t-1}] + b_c) \tag{3}$$

式中, W_c 表示连接权, b_c 表示激活函数的一个激活阈值。

输入门用于调整候选值 C_t 的大小,输入门的输出为

$$i_t = \sigma_i(W_i[x_t, h_{t-1}] + b_i) \tag{4}$$

式中, W_i 表示连接权, b_i 表示激活函数的一个激活阈值。候选值 C_t 经过输入门的调整,其值为 $C_t \cdot i_t$ 。

忘记门用于控制 LSTM 元的记忆状态 S_{t-1} ,忘记门的输出为

$$f_t = \sigma_f(W_f[x_t, h_{t-1}] + b_f) \tag{5}$$

式中, W_f 表示连接权, b_f 表示激活函数的一个阈值。记忆状态 S_{t-1} 经过忘记门的调整,其值为 $f_t \cdot S_{t-1}$ 。

此时, t 时刻的状态 S_t 由其所记忆的前一时刻状态 S_{t-1} 和状态更新的候选值加权得到:

$$S_t = f_t \cdot S_{t-1} + C_t \cdot i_t \tag{6}$$

输出门 o_t 当作状态 S_t 最终输出的一个权值,控制状态 S_t 的输出大小,输出门的公式为

$$o_t = \sigma_o(W_o[x_t, h_{t-1}] + b_o) \tag{7}$$

最终 LSTM 元的输出为

$$h_t = o_t \cdot \sigma_s(S_t) \tag{8}$$

式中, $\sigma_c, \sigma_i, \sigma_f, \sigma_o, \sigma_s$ 为激活函数。

为了确定时间延迟参数 L ,由 2.2 节可以看出,风速与波高的时间相关性约为 6~12 h。通过对不同海况下风速与浪高时间序列的时间相关性开展分析,选定时间相关性参数为 6。最终时间延迟参数 L 的计算公式如下:

$$L = \begin{cases} \frac{6}{\tau}, & \tau = 0.5, 1, 3, 6 \\ 1, & \tau = 12 \end{cases} \tag{9}$$

2.2 风速预测模型建模过程

以 0.5 h 为时间间隔,将风场数据 $x(t)$ 划分成各子序列 $x_i(k), k=1,2,\dots$ 。选取各子序列的最大值作为风场特征参数。由 1.2 节可知风速时间相关性为 48(即第 i 个样本与前 48 个样本有关)。

采用 LSTM 神经网络建立风场预测模型。其中, LSTM 层为 3 层, 各层节点数为 10。LSTM 层后连接 2 个全连接层, 每层节点数为 10。为了防止过拟合, 在两层全连接层之间设置一个 Dropout 系数为 0.5 的 Dropout 层。最后接一个输出层。输出维度为 1。训练次数为 500 次, 初始学习率为 0.05。

2.3 风速预测模型结果分析

图 7 给出了 R_s 与损失值随训练过程的变化曲线, 可以看出, 随着训练次数的不断增加, R_s 与损失值会迅速降低。

图 8 给出了风速预测模型的预测结果, 可以看出, 预测结果与实测结果具有较好的一致性, 预测结果较为准确, 预测残差较小。

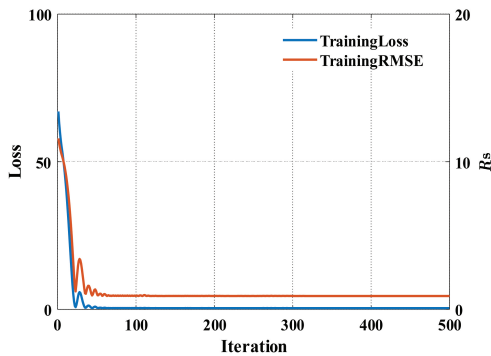


图 7 风速预测模型训练过程

Fig.7 Training process of wind speed forecast model

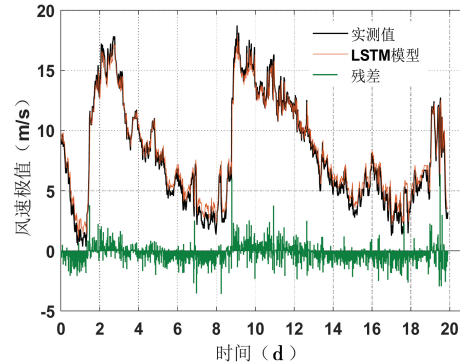


图 8 风速预测模型预测结果

Fig.8 Prediction results of wind speed forecast model

为了定量分析预测模型的准确性, 选取相关性系数 R^2 、均方根误差 R_s 作为指标。其中 R^2 表示预测结果与实测结果的相关程度, R_s 显示了预测结果与实测结果的平均误差。此外, 选取预测风场的准确率 ε 作为评估指标, 该指标也是天气预报中常用的指标之一。所选评估指标的计算公式如下:

$$R^2 = \frac{COV(X, Y)}{\sqrt{Var[X]Var[Y]}} \tag{10}$$

$$R_s = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \tag{11}$$

$$\varepsilon = \frac{N(I_{d_y}(i) = I_{d_x}(i))}{N(x)} \times 100\% \tag{12}$$

式中, x_i 和 y_i 分别表示实测结果与预测结果。 $I_{d_y}(i)$ 表示 y_i 对应的风场等级, $I_{d_x}(i)$ 表示 x_i 对应的风场等级。

表 3 给出了风速预测模型的预测误差。可以看出, 其相关性系数 R^2 为 0.9889, 预测 R_s 为 0.9664 m/s, 预测风场准确率为 98.54%, 准确率较高。可以看出所提模型可以对短期风速进行准确预测, 为平台的作业安全提供指导。

表 3 风速预测模型预测误差

Tab.3 Prediction error of wind speed forecast model

	R^2	$R_s/(m \cdot s^{-1})$	ε
LSTM 模型	0.9889	0.9664	98.54%

3 基于数据驱动的波浪预测模型

3.1 波高预测方法和深度学习建模过程

图 9 给出了单步预测模型的建模框架。对于不同的时间间隔 τ , 其对应的时间延迟参数 L 可以由公式(9)计算得出。将原始时间序列进行划分。计算得到各子序列的风速极值与波高极值。选取 $(t-L, \dots, t)$ 的风速极值和 $(t-1)$ 的波高极值作为输入参数, 将 t 的波高极值作为期望输出。

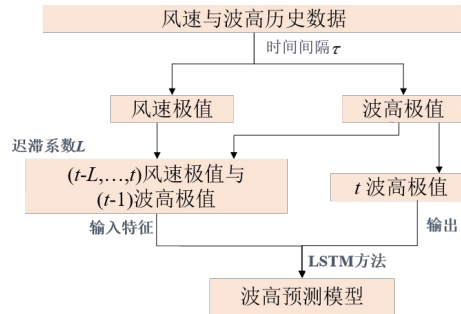


图 9 波高 LSTM 单步预测模型建模框架

Fig.9 Framework of one-step-ahead wave height LSTM prediction model

图 10 给出了预测模型输入输出的选取原则。基于 LSTM 神经网络建立输入特征与期望输出之间的关系模型。

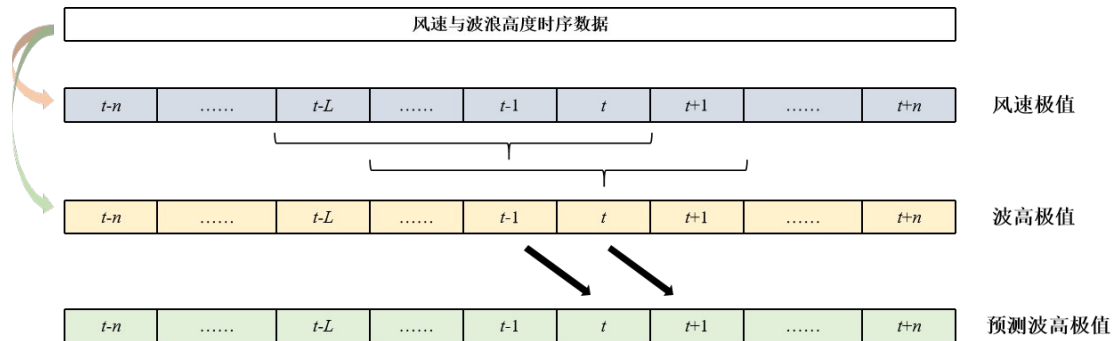


图 10 输入层与输出层选取原则

Fig.10 Selection principle of the input and output layer

图 11 给出了波高 LSTM 预测模型的网络框架结构。其中输入维度为 $L+2$, 输出维度为 1, LSTM 层数为 2, 每层节点数为 20。LSTM 层后连接 2 层全连接层, 每层节点数为 10, 为了避免过拟合问题, 在全连接层之间设置一个 Dropout 系数为 0.5 的 Dropout 层。选择均方误差作为损失函数, 并选择 Adam 优化器。初始学习率为 0.05, 训练次数为 500。

为了定量分析预测模型的准确性, 与风场预测模型分析方法相似, 选取相关性系数 R^2 , 均方根误差 R_s 及预测海况的准确率 ϵ 作为评估指标。

3.2 结果分析与讨论

以时间间隔 $\tau=0.5$ h 为例, 图 12 给出了 R_s 和损失值随训练过程的变化曲线。可以看出, 随着迭代次数的增加, R_s 和损失值均迅速下降, 最终收敛至接近于 0。

图 13 给出了波高 LSTM 模型的预测结果与实测结果的对比曲线。可以看出, 在时间间隔 $\tau=0.5$ h 时, 波高预测结果与实测结果之间有着较好的一致性, 说明该模型预测短时间间隔下波浪极值较为准确。

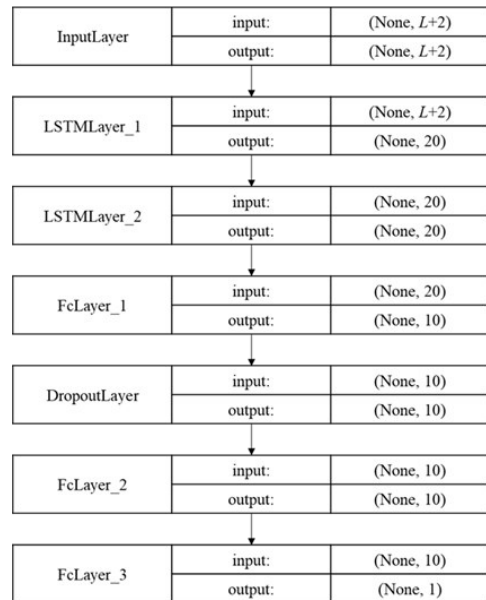


图 11 LSTM 模型结构

Fig.11 LSTM model structure

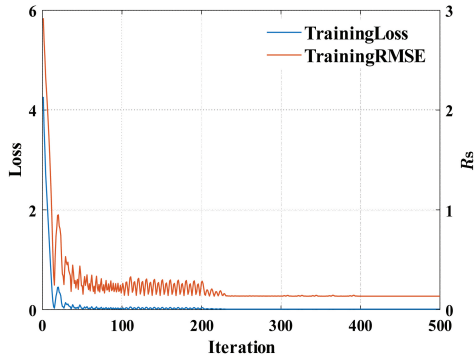


图 12 R_s 与损失值随训练过程的变化曲线

Fig.12 Variations of R_s and loss via training process

表 4 给出了当 $\tau=0.5$ 时单步预测模型(LSTM^{0.5h})的预测误差,可以看出预测模型的 R_s 仅为 0.12 m,相比于波高的变化范围来说,误差很小。另一方面,预测 ε 为 93.22%,说明准确预测的海况等级占比为 93.22%,对现场作业具有重要的工程意义。

为了验证该方法对于短时间间隔下波高预测的准确性,选用 DNN、BiLSTM、SVM、BP 等神经网络方法对该问题进行研究,并与 LSTM 模型进行对比。

图 14 给出了不同模型预测结果与实测结果的对比曲线,可以看出,基于 LSTM 方法的预测结果优于其它模型的预测结果。尤其在波高幅值较小时,其它模型的预测模型误差较大。BP 神经网络由于其网络层数较小,非线性程度较低等问题,误差最大。

表 5 给出了不同神经网络模型的预测误差,可以看出,本文 LSTM^{0.5h} 模型的 R_s 仅为 0.1186 m,小于其它神经网络模型的预测误差。同时,其相关性系数 R^2 为 0.9967,大于其它方法预测结果,说明本文所提方法可以更为准确地对波浪极值预测问题进行求解。

表 5 不同神经网络模型预测误差

Tab.5 Prediction errors of different neural network models

	LSTM ^{0.5h}	DNN	SVM	BiLSTM	BP
R^2	1	0.99	0.99	0.98	0.94
R_s	0.12	0.19	0.17	0.21	0.49

进一步选择两个不同的时间间隔($\tau=1.0$ h, 3.0 h)验证本节 LSTM 预测模型对较长时间间隔下波高的预测能力及精度。表 6 给出了不同时间间隔下的预测误差。可以看出,在时间间隔 $\tau=1.0$ h 和 3.0 h 等相对较短的时间间隔下,预测误差 R_s 分别为 0.12 m 和 0.16 m,预测误差较小。同时预测海况的准确率分别达到 93.22% 及 93.11%,表明所提单步预测模型可以对时间间隔 $\tau=3.0$ h 以内的波高进行较高精度的预测求解。

3.3 预测风速下的波浪预测结果

3.2 节预测结果是在风速结果已知的前提下得到,但利用预测风速进行波浪高度预测更具工程价

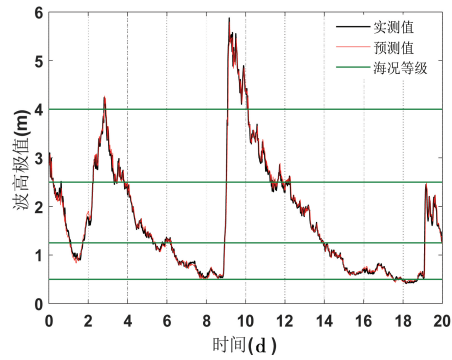


图 13 时间间隔 $\tau=0.5$ h 时波高预测结果

Fig.13 Wave height prediction results at $\tau=0.5$ h

表 4 LSTM^{0.5h} 模型预测误差

Tab.4 Prediction error of LSTM^{0.5h} model

	R^2	R_s	ε
LSTM ^{0.5h}	1	0.12m	93.22%




图 14 不同神经网络模型波高预测结果对比

Fig.14 Comparison of wave height prediction results under different neural network models

表 6 不同时间间隔 τ 的预测误差

Tab.6 Prediction errors under different time intervals τ

方法	R^2	R_s	ε
LSTM ^{0.5h}	1	0.12 m	93.22%
LSTM ^{1h}	0.99	0.16 m	93.11%
LSTM ^{3h}	0.98	0.33 m	84.91%

值。因此,将风速预测模型与波浪预测模型相结合,利用预测风速进行波浪高度预测。图15给出了预测风速下的预测波浪结果。可以看出,预测结果与实测结果具备高度的一致性,预测残差较小,预测结果较为准确。

为了与3.2节利用实测风速的波浪预测结果进行对比,图16给出了两种预测结果残差累积概率分布对比。可以看出,利用实测风速的波高预测残差略小于利用预测风速的波高预测残差,但两种预测残差均较小。

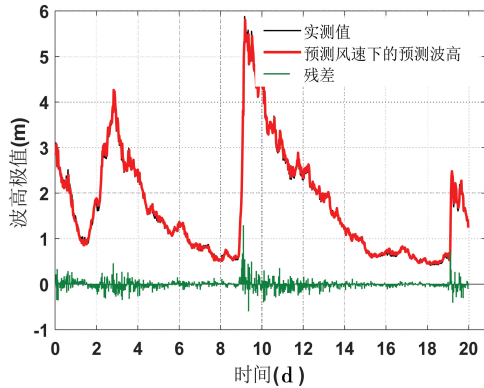


图15 预测风速下的预测波浪结果

Fig.15 Predicted results at predicted wind speed




图16 不同预测结果残差累计概率分布

Fig.16 Comparison of CDF of different prediction results

最终,计算可得预测风速下的波浪均方根误差 R_s 也为0.12 m。预测结果与利用实测风速下的预测模型基本一致。综上所述,本文提出的一种利用历史数据的风和波浪短期预测模型,其预测结果较为准确,具备较高的工程应用价值。

4 结 论

针对海洋环境中风和波浪复杂多变、难以准确预测的问题,本文提出了一种基于考虑时间相关性的风和波浪高度短期预测方法,所提方法可以对风场与波浪高度进行准确预测。本文主要得到了以下三个结论:

(1) 提出了一种南海风速深度学习预测模型,考虑了时间相关性。由预测结果可以看出,预测均方根误差仅为0.97 m/s,预测准确率达到98%以上,结果较为准确。并对该模型在台风等恶劣海况下的适用程度进行了验证,在台风“海鸥”海况下的预测均方根误差仅为0.98 m/s,表明该模型在台风等恶劣海况下具备较强的泛化性能。

(2) 提出了一种波浪高度单步预测深度学习 LSTM 模型,在时间间隔为0.5 h的情况下,预测均方根误差仅为0.12 m。相比于其它神经网络方法,预测结果较为准确。

(3) 建立了风与波浪联合预测模型,最终预测风速下的波浪预测均方根误差仅为0.12 m,相比利用实测数据的波浪预测结果,预测误差基本一致。

参 考 文 献:

- [1] Zijlema M. Computation of wind-wave spectra in coastal waters with SWAN on unstructured grids[J]. Coastal Engineering, 2010, 57(3): 267-277.
- [2] Booij N, Holthuijsen L H. Propagation of ocean waves in discrete spectral wave models[J]. Journal of Computational Physics, 1987, 68(2): 307-326.

- [3] Ris R C, Holthuijsen L H, Booij N. A third-generation wave model for coastal regions: 2. Verification[J]. *Journal of Geophysical Research: Oceans*, 1999, 104(C4): 7667–7681.
- [4] Booij N, Ris R C, Holthuijsen L H. A third-generation wave model for coastal regions: 1. Model description and validation [J]. *Journal of Geophysical Research*, 1999, 104(C4): 7649–7666.
- [5] Hasselmann S, Hasselman K, Bauer E, et al. The WAM model—A 3rd generation ocean wave prediction model[J]. *Journal of Physical Oceanography*, 1988, 18(12): 1775–1810.
- [6] Gunther H, Hasselmann S, Janssen P. The WAM model cycle 4[R]. Hamburg (Germany): Deutsches Klimarechenzentrum (DKRZ), 1992.
- [7] Komen G J, Cavaleri L, Donelan M, et al. Dynamics and modelling of ocean waves[J]. *Earth-Science Reviews*, 1995, 39(1–2): 111–113.
- [8] Hersbach H, Janssen P. Improvement of the short-fetch behavior in the Wave Ocean Model (WAM)[J]. *Journal of Atmospheric and Oceanic Technology*, 1999, 16(7): 884–892.
- [9] Tolman H L. User manual and system documentation of WAVEWATCH III version 3.14[M]. 2009.
- [10] Tolman H L, Chalikov D. Source terms in a third-generation wind wave model[J]. *Journal of Physical Oceanography*, 1996, 26(11): 2497–2518.
- [11] Tolman H L, Balasubramaniyan B, Burroughs L D, et al. Development and implementation of wind-generated ocean surface wave models at NCEP[J]. *Weather and Forecasting*, 2010, 17(2): 311–333.
- [12] Hasselmann K. Measurements of wind-wave growth and swell decay during the Joint North Sea Wave Project (JONSWAP) [J]. *Dtsch. Hydrogr. Z.*, 1973, 8: 1–95.
- [13] Ou S H, Liau J M, Hsu T W, et al. Simulating typhoon waves by SWAN wave model in coastal waters of Taiwan[J]. *Ocean Engineering*, 2002, 29(8): 947–971.
- [14] Rogers W E, Kaihatu J M, Hsu L, et al. Forecasting and hindcasting waves with the SWAN model in the Southern California Bight[J]. *Coastal Engineering*, 2007, 54(1): 1–15.
- [15] Mentaschi L, Besio G, Cassola F, et al. Performance evaluation of Wavewatch III in the Mediterranean Sea[J]. *Ocean Modelling*, 2015, 90: 82–94.
- [16] Kalourazi M Y, Siadatmousavi S M, Yeganeh-Bakhtiary A, et al. WAVEWATCH-III source terms evaluation for optimizing hurricane wave modeling: A case study of Hurricane Ivan[J]. *Oceanologia*, 2020, 63(2): 194–213.
- [17] 付睿丽. 长峰极端波浪的统计特性和预报方法研究[D]. 大连: 大连理工大学, 2021.
Fu R L. Study on statistical characteristics and prediction methods of long-crested extreme waves[D]. Dalian: Dalian University of Technology, 2021
- [18] 王 焕. 南海海域波浪时空变化特征分析及有效波高预测研究[D]. 湛江: 广东海洋大学, 2021.
Wang H. Analysis of spatial-temporal characteristics of waves and prediction of significant wave height in the South China Sea[D]. Zhanjiang: Guangdong Ocean University, 2021.
- [19] Deo M C, Naidu C S. Real time wave forecasting using neural networks[J]. *Ocean Engineering*, 1998, 26(3): 191–203.
- [20] Mandal S, Prabaharan N. Ocean wave forecasting using recurrent neural networks[J]. *Ocean Engineering*, 2006, 33(10): 1401–1410.
- [21] Mahjoobi J, Mosabbeh E A. Prediction of significant wave height using regressive support vector machines[J]. *Ocean Engineering*, 2009, 36(5): 339–347.
- [22] Demetris D, Michailides C, Papanastasiou G, et al. Coastal zone significant wave height prediction by supervised machine learning classification algorithms[J]. *Ocean Engineering*, 2021, 221(6): 108592.
- [23] Alexandre E, Cuadra L, Nieto-Borge J C, et al. A hybrid genetic algorithm—extreme learning machine approach for accurate significant wave height reconstruction[J]. *Ocean Modelling*, 2015, 92: 115–123.
- [24] 黄心裕, 唐 军, 王晓宇. 基于 Prophet 算法的海南近海波浪长时段时序分析与预测[J]. *海洋学报*, 2022, 44(4): 114–121.
Huang X Y, Tang J, Wang X Y. Long term time series analysis and prediction of waves at Hainan offshore zone based on Prophet algorithm[J]. *Haiyang Xuebao*, 2022, 44(4): 114–121.

- [25] 郝 伟, 黄礼敏, 王晨羽, 等. 海浪有义波高预报方法对比分析研究[C]//第十六届全国水动力学学术会议暨第三十二届全国水动力学研讨会论文集(下册), 2021.
Hao W, Huang L M, Wang C Y, et al. Comparative analysis on prediction methods of significant wave heights[C]//Proceedings of the 16th National Hydrodynamics Academic Conference and the 32nd National Hydrodynamics Symposium (Volume 2), 2021.
- [26] Yao J, Wu W H. Wave height forecast method with multi-step training set extension LSTM neural network[J]. Ocean Engineering, 2022, 263: 112432.
- [27] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1935-1980.