



## 疏浚工程作业水域波浪的快速预测

郝宇驰<sup>1,2</sup>, 曲嘉铭<sup>2</sup>, 林斌良<sup>1</sup>, 张晴波<sup>2</sup>

(1. 清华大学水利水电工程系, 北京 100084;

2. 中交疏浚技术装备国家工程研究中心有限公司, 上海 200082)

**摘要:** 针对耙吸船耙臂系统等疏浚机具操作受波浪影响问题, 及其对疏浚船作业过程中波浪的快速预测要求, 基于ConvLSTM神经网络模型建立了面向疏浚船作业海域的波浪快速预测模型, 利用疏浚工程海域的波高、周期的数值模拟后报结果数据作为训练样本, 对波浪预测网络模型进行训练。结果表明: 所建立的神经网络对疏浚工程海域的波浪预测所需时间仅2~5 s, 对作业海域波高分布的前向6 h的波浪预测相关度达0.956; 当预测步长增大到12 h后, 受训练数据不均衡影响, 神经网络对波浪的预测精度明显下降至0.849。因此, 模型可用于疏浚作业海域进行波浪的短时快速预测, 为船舶安全操作提供依据。

**关键词:** 疏浚工程; 波浪数学模型; 波浪预测; 神经网络; ConvLSTM

中图分类号: U616

文献标志码: A

文章编号: 1002-4972(2025)09-0023-07

### Rapid waves prediction in dredging project operation water area

HAO Yuchi<sup>1,2</sup>, QU Jiaming<sup>2</sup>, LIN Binliang<sup>1</sup>, ZHANG Qingbo<sup>2</sup>

(1. Department of Hydraulic Engineering, Tsinghua University, Beijing 100084, China;

2. CCCC National Engineering Research Centre of Dredging Co., Ltd., Shanghai 200082, China)

**Abstract:** Aiming at the problem that the operation of dredging equipment such as the trailing arm system is affected by waves, and the requirement for rapid prediction of waves during the operation of dredging ship, a rapid wave prediction model for the operation sea area of dredgers is established based on the ConvLSTM neural network model. The numerical simulation results of wave height and period in the dredging project sea area are used as training samples to train the wave prediction network model. Based on the analysis of the demand for rapid wave prediction in the dredging operation process, this paper proposes ConvLSTM-based neural network models for rapid wave prediction in dredging project areas. The models are trained using retrospective data from traditional wave mathematical models, enabling accurate and rapid prediction of wave height and period in dredging operation water areas. The results show that the established neural network required only 2–5 s for wave prediction in the dredging project, and the correlation of wave prediction for the forward 6 h wave height distribution in the operating sea area reaches 0.956. When the prediction step size increases to 12 h, the neural network's prediction accuracy for waves significantly decreases to 0.849 due to the uneven training data. Therefore, this model can be used for short-term and rapid wave prediction in dredging operation areas, providing a basis for safe operation of ships.

**Keywords:** dredging project; wave mathematical models; wave prediction; neural network; ConvLSTM

自航耙吸挖泥船是一种在港航疏浚工程中可自行航行进行疏浚施工的船舶<sup>[1]</sup>, 在疏浚作业过

程中不会阻碍水域内的其他船舶航行, 可以在航行距离较远海域、开阔海域等海况条件进行

收稿日期: 2024-12-16

作者简介: 郝宇驰 (1981—), 男, 硕士, 正高级工程师, 从事疏浚技术研究工作。

疏浚作业,且易于调遣,属于我国航道、港口建设中的重要疏浚船类型。

耙吸船在航行、下耙、疏浚和抛泥等作业过程中,船体及耙臂系统在波浪作用下产生的纵荡、横荡等运动,对疏浚的安全和效率产生重要影响。随着疏浚技术的不断发展,耙吸挖泥船装备整体呈现出大型化、远海化发展趋势,需要面临更加复杂多变的水文气象环境和施工工况。由于外海波浪作用显著,给船舶的疏浚作业带来了巨大的挑战,导致疏浚效率降低和成本显著增加,乃至船舶装备受损、无法安全作业等问题<sup>[2]</sup>。

由于外海作业环境的复杂性,对疏浚海域的波浪潮流预测的需求变得迫切<sup>[3]</sup>。通过技术手段准确地预测波高、周期和传播方向等数据,能够帮助疏浚工程人员更加合理地规划疏浚过程,及时调整作业计划,确保疏浚工程在安全高效的前提下顺利进行,从而提高作业效率、降低成本<sup>[4-6]</sup>。

在波浪预测方面,国内外所开展的数值模拟主要面向大范围海域,空间范围在几十千米到数百千米之间,时间尺度在数天与数周<sup>[7-9]</sup>,而主流耙吸船的结构尺度为百米级,因此,为满足疏浚作业安全需求,需要为疏浚工程提供船舶尺度(<100 m)的波浪预测数据。精度提升意味模拟计算量的指数级增大,如果要在疏浚作业过程中实现持续的预测,对计算硬件的要求极大,成本也难以满足工程经济性的要求。

随着人工智能技术的发展,支持向量机(support vector machines, SVM)、极限学习机(extreme learning machine, ELM)、残差网络(ResNet)等深度学习网络被应用于波浪的预测,通过大量历史数据训练,实现线性和非线性特点的预测,且其稳定性和准确性逐渐得到业内认可。其中, Ghorbani 等<sup>[10]</sup>提出预测波浪参数的增强混沌多元线性回归方法; Kumar 等<sup>[11]</sup>介绍了有效波高的时间序列学习方法预测区域有效波高; Pirhooshyaran 等<sup>[12]</sup>使用有效波高的时间序列学习网络来预测波高,论述了主要特征参数的选择方

法,并利用附近观测站的数据重建缺失波观测结果; Bai G 等<sup>[13]</sup>基于卷积神经网络预测海域的有效波高,发现在众多网络中长短时记忆神经网络(long short-term memory, LSTM)对有效波高的预测准确性最高;尚凡成等<sup>[14]</sup>提出一种结合生成式对抗思想的神经网络,实现了波浪的极短期时序预测。然而,目前已开展的相关研究多局限在单一神经网络模型,并且没有充分利用诸如频谱特征等已知数据,因此预测的适应性和精度受限,尚无法满足疏浚船施工过程对波浪快速预测的需求。

针对上述需求和当前预测技术存在的问题,本文将传统数值模拟技术与神经网络预测技术相结合,建立预测疏浚工程海域波浪的卷积长短时记忆神经网络(ConvLSTM),基于波浪后报数据进行算法训练,实现了对疏浚工程海域波高、周期的快速预测。

## 1 需求分析

耙吸挖泥船(trailing suction hopper dredger, TSHD)需要在航行中下放耙臂进行疏浚施工。在耙臂收放过程中,如果作业水域中波高较大,则耙臂推出舷外入水与耙臂出水上架的操作过程受波浪影响最为明显,有可能撞击船舷,造成损坏。一旦耙臂入水,风险就显著降低。因此,需要在操作时对船舶航行前方作业水域的波浪进行快速预测,以选择最有利的操作时机,使船在小浪时段上下耙,确保疏浚作业的安全。

根据耙吸挖泥船航行过程中疏浚作业的特点,对波浪快速预测的时间范围进行估算,预测时长( $t_p$ )与船舶设备调整时长( $t_a$ )之和应小于预测起始时刻船舶与波浪间距离时间差,见图1。

具体表达式为:

$$t_p + t_a < D / (v_w + v_s) \quad (1)$$

$$D = (v_w + v_s) \cdot t_p + d_r \quad (2)$$

式中:  $v_w$  为波浪移动速度;  $v_s$  为船舶移动速度;  $t_p$  为一次预测波浪要素时长;  $t_a$  为船舶设备调整为适宜预测波浪施工所需时间;  $d_r$  为一次波浪要

素预测后船与波浪间剩余距离;  $D$  为预测起始时刻船舶与波浪间距离。




图 1 耙吸船航行过程时间分析

Fig. 1 Navigation process analysis diagram of TSHD

以距船舶 3 000 m 之外的海上波浪传播为例, 典型风浪的波周期主要分布于 3~6 s 区间, 对应的波浪传播速度约 2.7~4.2 m/s, 疏浚船施工中的航速一般为 2~4 kn (约 1.03~2.06 m/s)。根据式 (1) 和 (2), 波浪与挖泥船的会遇时间约 8 min, 为满足疏浚施工和安全操作响应的的时间要求, 波浪要素的预测计算所需时间  $t_p$  和耙吸船的操作时间  $t_a$  之和应小于会遇时间。传统数值模拟方法由于其建模和计算所需要的时间等问题, 难以实现耙吸挖泥船安全施工所需的船舶尺度快速波浪预测。

## 2 预测方法

### 2.1 基础神经网络模型

针对疏浚作业海域的波浪预测, 属于面域波浪要素场景。从单一时序预测演变为时空预测可能存在空间信息丢失的问题。为更好地描述波浪的场特征, 本文基于 LSTM 单元, 建立 ConvLSTM 时空神经网络模型, 展开对作业海域的波浪预测。在 LSTM 网络基础上, 该网络将每个门中的矩阵乘法运算替换为卷积运算, 至此实现输入数据为 3D 结构, 网络可通过在多维数据中进行卷积操作

捕获基础空间特征。其在一个单元内的具体表达式为:

$$i_t = \sigma(W_{x,i} * x_t + W_{h,i} * h_{t-1} + W_{c,i} \circ c_{t-1} + b_i) \quad (3)$$

$$f_t = \sigma(W_{x,f} * x_t + W_{h,f} * h_{t-1} + W_{c,f} \circ c_{t-1} + b_f) \quad (4)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_{x,c} * x_t + W_{h,c} * h_{t-1} + b_c) \quad (5)$$

$$o_t = \sigma(W_{x,o} * x_t + W_{h,o} * h_{t-1} + W_{c,o} \circ c_t + b_o) \quad (6)$$

$$h_t = o_t \circ \tanh c_t \quad (7)$$

式中:  $i_t$  为输入门;  $f_t$  为遗忘门;  $o_t$  为输出门;  $c_t$  为当前时刻状态;  $c_{t-1}$  为上一时刻状态;  $h_{t-1}$  和  $h_t$  分别为前一时间步和当前输出的隐藏状态;  $x_t$  为时间步  $t$  的输入数据;  $W_{x,i}$  为输入门的输入权重;  $W_{x,f}$  为遗忘门的输入权重;  $W_{x,c}$  为状态门的输入权重;  $W_{x,o}$  为输出门的输入权重;  $W_{h,i}$  为输入门的隐藏状态权重;  $W_{h,f}$  为遗忘门的隐藏状态权重;  $W_{h,c}$  为状态门的隐藏状态权重;  $W_{h,o}$  为输出门的隐藏状态权重;  $W_{c,i}$  为输入门细胞状态的权重系数;  $W_{c,f}$  为遗忘门细胞状态的权重系数;  $W_{c,o}$  为输出门状态的权重系数;  $b_i$  为输入门的偏置系数;  $b_f$  为遗忘门的偏置系数;  $b_c$  为当前状态的偏置系数;  $b_o$  为输出门的偏置系数;  $\circ$  为哈达玛乘积;  $\sigma$  为 sigmoid 函数;  $*$  为卷积。

所建立的模型网络采用 encoding-forecasting 结构, 见图 2。预测网络 (forecasting) 的初始状态和输出是从编码网络 (encoding) 的最后状态复制, 并通过叠加数个 ConvLSTM 层形成。由于预测目标具有与输入相同的维数, 可将预测网络中的所有状态连接起来, 并将其输入至一个  $1 \times 1$  卷积层中生成预测终值。

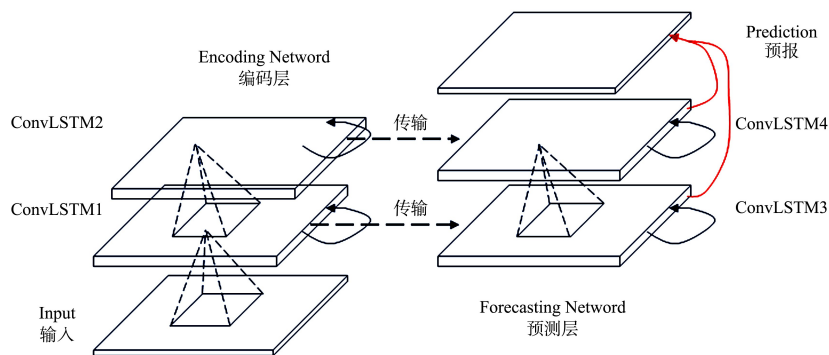


图 2 ConvLSTM 的 encoding-forecasting 结构

Fig. 2 Encoding-forecasting structure of ConvLSTM

## 2.2 模型建立

基于 ConvLSTM 建立耙吸船疏浚作业海域波浪时空分布的专用网络。以前  $n$  个连续时间步长的波高、风向、风速 (10 m 海拔) 作为输入, 对后  $n$  个时间步长进行预测, 每次向前推进  $n$  个时间步长。通过 3 层 ConvLSTM 层以及 1 层 Conv3D 输出层, 获得未来  $n$  小时的波高预测结果 (分别选取  $n$  为 6 和 12 h)。在卷积过程中未加入池化层或上采样层, 使用填充设置使得中间过程生成的特征图大小一致。ConvLSTM 的损失函数选用 L2 loss, 学习率为 0.000 1。ConvLSTM 波高预测模型框架见图 3。

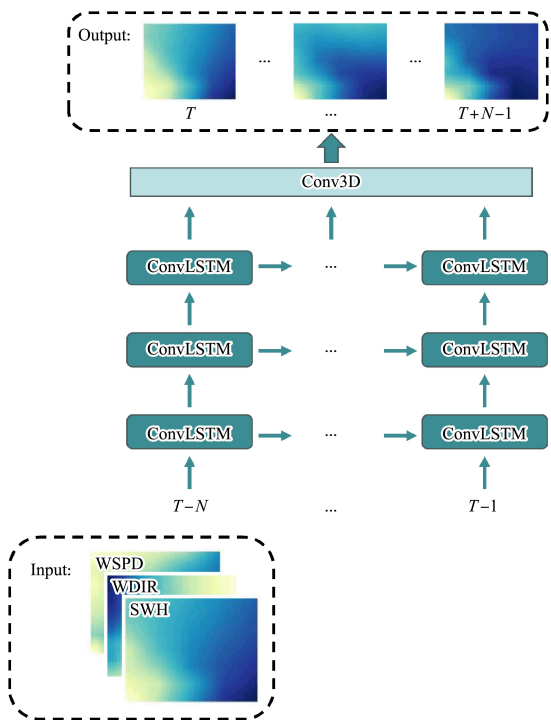


图 3 ConvLSTM 波高预测模型框架  
Fig. 3 ConvLSTM wave height prediction model framework

## 3 训练数据获取

### 3.1 波浪后报模型

基于 Navier-Stokes 方程构建潮流预测数学模型, 通过对三维水平动量方程和连续方程沿水深积分, 忽略水体的垂向差异, 得到二维浅水方程:

$$\frac{\partial \eta}{\partial t} + \frac{\partial (hu)}{\partial x} + \frac{\partial (hv)}{\partial y} = 0 \quad (8)$$

$$\frac{\partial u}{\partial t} + u \frac{\partial u}{\partial x} + v \frac{\partial v}{\partial y} + g \frac{\partial \eta}{\partial z} + c_f \frac{u \sqrt{u^2 + v^2}}{h} - v_H \left( \frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) = f_v + M_x \quad (9)$$

$$\frac{\partial v}{\partial t} + u \frac{\partial u}{\partial x} + v \frac{\partial v}{\partial y} + g \frac{\partial \eta}{\partial x} + c_f \frac{u \sqrt{u^2 + v^2}}{h} - v_H \left( \frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} \right) = f_u + M_y \quad (10)$$

$$c_f = g \frac{n^2}{3\sqrt{h}} \quad (11)$$

式中:  $x$ 、 $y$  分别为笛卡尔坐标系中东向、北向的坐标;  $t$  为时间;  $\eta$  为水位, m;  $h$  为水深, m;  $u$ 、 $v$  分别为  $x$ 、 $y$  方向上的垂向平均流速, m/s;  $g$  为重力加速度, m/s<sup>2</sup>;  $v_H$  为水平涡黏性系数, m<sup>2</sup>/s;  $f_v$ 、 $f_u$  分别为科氏力在  $x$ 、 $y$  方向上的分量;  $M_x$ 、 $M_y$  分别为  $x$ 、 $y$  方向外部动量源汇项, m/s<sup>2</sup>;  $c_f$  为无量纲摩擦系数;  $n$  为曼宁系数, s/m<sup>1/2</sup>。

采用 ADI 法 (alternating direction implicit method) 求解动量守恒方程和连续方程, 得到每个时间步长的潮流场。时间步长  $\Delta t$  由 CFL 数 (Courant-Friedrichs-Lewy number) 确定:

$$N_{\text{CFL}} = 2\Delta t \sqrt{gh \left( \frac{1}{\Delta x^2 + \Delta y^2} \right)} < 4\sqrt{2} \quad (12)$$

式中:  $N_{\text{CFL}}$  为 CFL 数;  $\Delta x$  和  $\Delta y$  为  $x$ 、 $y$  方向最小网格尺寸。

采用第三代波浪谱模型, 基于矩形或正交曲线网格计算波浪谱:

$$\frac{\partial N}{\partial t} + \frac{\partial (C_x N)}{\partial x} + \frac{\partial (C_y N)}{\partial y} + \frac{\partial (C_\omega N)}{\partial \omega} + \frac{\partial (C_\theta N)}{\partial \theta} = \frac{S}{\omega} \quad (13)$$

式中:  $\omega$  为相对角频率;  $\theta$  为波浪传播方向;  $C_x$ 、 $C_y$  为波浪沿  $x$ 、 $y$  方向的传播速度;  $C_\omega$ 、 $C_\theta$  为波浪沿  $\omega$ 、 $\theta$  方向的空间传播速度;  $S$  为源函数;  $N$  为波作用量密度。

式 (13) 中的波谱作用量平衡描述了全波谱在时空上的缓慢变化, 可通过对所有频率积分进行简化, 得到随时间变化的函数, 其中  $N$  代表波作用量密度, 它是角频率  $\omega$  和方向  $\theta$  的函数:



$$N(\omega, \theta) = \frac{E(\omega, \theta)}{\omega} \quad (14)$$

式中:  $E$  为波能量密度;  $N$  为波作用量密度; 它是角频率  $\omega$  和方向  $\theta$  的函数。

运用基于线性波理论的表达式来描述相关波作用量的平衡分量。单个自由表面重力波分量 ( $\omega$  和  $\theta$  方向上) 的波能是其势能和动能之和:

$$E_\omega = \frac{1}{2} \rho_w g c^2 \quad (15)$$

式中:  $E_\omega$  为势能与动能之和;  $\rho_w$  为水的密度;  $c$  为每个波浪分量传播的速度。

式 (13) 右侧的  $S$  代表以谱密度表示“源”和“汇”项, 描述了风能输入、波与波之间的非线性相互作用和由白浪耗散、底摩擦和浅水波浪破碎等引起的能量耗散, 其计算公式为:

$$S = S_{in} + S_{nl} + S_{ds} + S_{bot} + S_{surf} \quad (16)$$

式中:  $S_{in}$  为风传输到波浪的能量, 即风-波相互作用项;  $S_{nl}$  为波与波之间的非线性相互作用项;  $S_{ds}$  为白浪耗散项;  $S_{bot}$  为底摩擦耗散项;  $S_{surf}$  为水深变浅引起的破碎项。

### 3.2 波浪后报数据获取

通过所建立的波浪潮流模型进行目标海域后报模拟, 模拟结果作为训练的数据, 网格覆盖的区域范围是  $70^\circ\text{E}$ — $140^\circ\text{E}$ ,  $0^\circ\text{N}$ — $60^\circ\text{N}$ , 模型范围见图 4。




图 4 波浪后报模型区域分布

Fig. 4 Regional distribution of wave post forecasting model

外海开边界设在黄东海海域, 由  $M_2$ 、 $S_2$ 、 $K_1$ 、 $O_1$ 、 $N_2$ 、 $K_2$ 、 $P_1$  和  $Q_1$  等 8 个主要分潮驱动, 各分潮的调和常数由 OTIS (OSU tidal prediction software) 潮汐预报模型获得, 风场边界条件来源于 GFS (global forecasting system) 数据库, 空间分辨率

为  $0.25^\circ \times 0.25^\circ$ , 时间分辨率为 3 h。

模型得到的后报数据格式为 NetCDF, 数据的时间范围是 2017 年 1 月 1 日—2022 年 12 月 31 日, 时间分辨率为 1 h。

为形成用于网络模型训练的数据, 将所选取目标区域的后报数据转换为 Tensor 数据类型:

1) 确定训练数据集。训练集空间分辨率为  $0.05^\circ \times 0.05^\circ$ , 其中在近岸长江口、连云港等目标海域的最小嵌套网格为 50 m。

2) 训练数据集的内容。本文选取的数据集包括有效波高、有效波周期、波向、风向、风速及经纬度坐标。

3) 数据处理。为满足预测要求, 选用 Min-Max 方法对数据做归一化处理, 以消除量纲影响, 转换函数如下:

$$\tilde{x} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (17)$$

式中:  $x_{\max}$  和  $x_{\min}$  分别为样本数据的最大值和最小值。

4) 数据转换。根据预测模型的输入数据、输出数据步长需求, 将数据处理成目标维度, 并转换为张量类型。输入数据范围为  $122^\circ\text{E}$ — $124^\circ\text{E}$ ,  $30^\circ\text{N}$ — $33^\circ\text{N}$ , 数据格式见表 1。

表 1 数据格式说明

Tab. 1 Data format specifications

数据名称	变量	时间段
训练和测试集	连续 $n$ 时间步长的波高、风向、10 m 风速 (张量维度为 $3 \times 21 \times 31 \times n$ , 其中 $n$ 为 6 或 12 h)	2017—2019 年的逐小时后报数据
预测集	后 $n$ 个时间步长的波高 (张量维度为 $1 \times 21 \times 31 \times n$ , 其中 $n$ 为 6 或 12 h)	2020 年的逐小时后报数据

## 4 预测结果分析

### 4.1 检验参数

本文采用均方根误差  $R_{\text{MSE}}$  作为评估模型预测误差的指标, 可表现模型预测数据与后报数据之间的离散程度; 选用相关系数  $C_c$  来表现预测数据与后报数据之间的相关性。表达式如下:

$$R_{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (H_p - H_m)^2} \quad (18)$$

$$C_c = \frac{\frac{1}{n} \sum_{i=1}^n [(H_p - \bar{H}_p) (H_m - \bar{H}_m)]}{\sqrt{\frac{1}{n} \sum_{i=1}^n (H_p - \bar{H}_p)^2} \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (H_m - \bar{H}_m)^2}} \quad (19)$$

式中： $n$  为时间序列总量； $H_p$  为预测波高； $H_m$  为后报数据波高； $\bar{H}_p$  和  $\bar{H}_m$  分别为对应的平均值。

#### 4.2 预测结果

利用后报数据对所建立的波浪时空预测模型进行训练，训练完成后利用该模型对作业海域的波高、周期和波向 3 个特征参数分布进行预测，并将预测结果与后报数据的预测集进行对比，结果见图 5。从图中可以看出，模型的波浪预测具有较好的整体趋势一致性，能够准确地预测波峰与波谷的位置。当预测时序从前向 6 h 增长为前向 12 h 时，预测结果出现微小的时滞性。同时，模型在前向 6 h 的预测表现较为准确，在前向 12 h 的预测中波峰位置出现一定偏差，预测值偏小，且实际波高越大的波峰位置误差越显著。

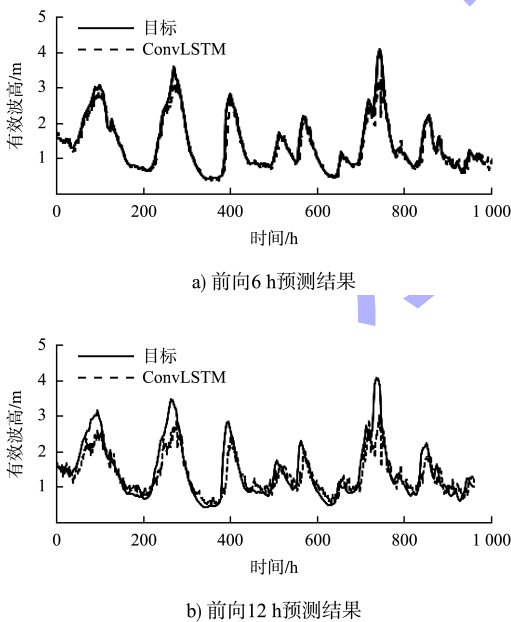


图 5 ConvLSTM 模型预测波高结果对比  
Fig. 5 Comparison of predicting wave height results of ConvLSTM model

本文分别计算了模型的预测结果与后报数据间的均方根误差  $R_{MSE}$  和相关系数  $C_c$ ，用以评估模型的预测精度，可以发现在前向 6 h 的预测中，模

型的  $R_{MSE}$  为 0.179 m (较小)， $C_c$  为 0.956；当预测步长增长为前向 12 h 时， $R_{MSE}$  增加至 0.326 m， $C_c$  明显下降至 0.849。造成该现象的原因可能是由于选用全年资料对模型进行训练，其中波高大于 3 m(对应于 5 级海况)的数据仅占全年数据的 8%，这类数据的不均衡问题可能导致模型在训练过程中对波高大的样本学习不足，使得 ConvLSTM 对于样本数据不均衡问题呈现一定的敏感性。

从预测时间效率方面，本模型完成目标海域 6 h 预见期的预测所需时间为 2~5 s，与之相比，常规数值模拟开展 50 m 嵌套网格模拟所需时间约数小时；如果覆盖海域范围大、网格数量多，则需要更多的时间进行模拟计算。因此，通过本文所建立的预测模型，可利用目标海域前期得到的大量后报数据，训练得到精度满足疏浚作业要求的快速预测模型，实现对波高和波周期等特征参数的高精度快速预测，从而有助于提升作业船舶的操作可靠性。

#### 5 结论

1) 本文将 ConvLSTM 神经网络应用于疏浚工程海域的波浪时空特征预测，针对性解决了传统数值模拟耗时较长的问题，实现了波高与周期的快速预测，预测时间为 2~5 s。

2) 经验证，该模型在前向 6 h 的波浪预测中，相关系数达到 0.956，预测精度较高；当预测时间步长增至 12 h 时，由于训练数据分布不均衡，模型预测精度下降较明显，相关系数减小至 0.849，这表明模型在长步长预测条件下仍有优化空间。通过分析，模型能够较为准确地预测波高的趋势性变化，包括波峰和波谷的位置分布。同时，预测误差表现在波高较大的区域较为显著，这是由训练数据中大波高的样本比例较低所致。

3) 本文提供了一种高效的疏浚作业海域波浪预测方法，在计算效率上优于传统数值模拟，且具备满足工程需求的预测精度，可为疏浚设备操作过程中选择最优作业时机提供数据支撑，保障作业安全性。

## 参考文献:

- [1] VAN RHEE C. Modelling the sedimentation process in a trailing suction hopper dredger [J]. *Terra et aqua*, 2002: 86.
- [2] 汪春晖. 耙吸挖泥船耙头波浪补偿系统工作压力与动力响应[D]. 上海: 上海交通大学, 2020.
- WANG C H. Working pressure and dynamic response of wave compensation system for drag head of a trailing suction hopper dredger[D]. Shanghai: Shanghai Jiao Tong University, 2020.
- [3] 戴江山, 张雷. 波浪与系缆方式对系泊船舶响应的影响研究[J]. *水运工程*, 2024(6): 51-57.
- DAI J S, ZHANG L. Influence of wave and mooring methods on responses of moored ships [J]. *Port & waterway engineering*, 2024(6): 51-57.
- [4] PIRHOOSHYARAN M, SNYDER L V. Forecasting, hindcasting and feature selection of ocean waves via recurrent and sequence-to-sequence networks [J]. *Ocean engineering*, 2020, 207: 107424.
- [5] FAN S T, XIAO N H, DONG S. A novel model to predict significant wave height based on long short-term memory network[J]. *Ocean engineering*, 2020, 205: 107298.
- [6] 张泽国, 尹建川, 柳成, 等. 基于 SAPSO-BP 网络模型的港口潮汐实时预报[J]. *水运工程*, 2017(1): 34-40.
- ZHANG Z G, YIN J C, LIU C, et al. SAPSO-BP network in tidal level prediction of port [J]. *Port & waterway engineering*, 2017(1): 34-40.
- [7] 王晓惠, 施渊, 沈旭伟, 等. 基于随机森林算法的波浪参数降尺度预报模型[J]. *长沙理工大学学报(自然科学版)*, 2025, 22(1): 62-70.
- WANG X H, SHI Y, SHEN X W, et al. Wave parameter downscaling forecasting model based on random forest algorithm[J]. *Journal of Changsha University of Science and Technology (natural science)*, 2025, 22(1): 62-70.
- [8] 金阳, 韩磊, 金梅兵, 等. 基于 ConvLSTM 的中国东南沿海波浪智能预报和评估[J]. *海洋学研究*, 2024, 42(3): 88-98.
- JIN Y, HAN L, JIN M B, et al. Intelligent wave forecasting and evaluation along the southeast coast of China based on ConvLSTM method[J]. *Journal of marine sciences*, 2024, 42(3): 88-98.
- [9] 袁祖晴, 高寒旭, 胡翌哲, 等. NCEP/NOAA 全球预报产品在江苏近岸及长江口外的精度评估[J]. *海洋预报*, 2024, 41(4): 32-42.
- YUAN Z Q, GAO H X, HU Y Z, et al. Accuracy assessment of the NCEP/NOAA global forecasting product around Jiangsu coastal region and Yangtze River estuary[J]. *Marine forecasts*, 2024, 41(4): 32-42.
- [10] GHORBANI M A, ASADI H, MAKARYNSKY O, et al. Augmented chaos-multiple linear regression approach for prediction of wave parameters [J]. *Engineering science and technology, an international journal*, 2017, 20(3): 1180-1191.
- [11] 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.
- [12] PIRHOOSHYARAN M, SNYDER L V. Forecasting, hindcasting and feature selection of ocean waves via recurrent and sequence-to-sequence networks[J]. *Ocean engineering*, 2020, 207: 107424.
- [13] BAI G, WANG Z F, ZHU X Y, et al. Development of a 2D deep learning regional wave field forecast model based on convolutional neural network and the application in South China Sea [J]. *Applied ocean research*, 2022, 118: 103012.
- [14] 尚凡成, 李传庆, 詹可, 等. 改进 LSTM 神经网络在极短期波浪时序预报中的应用[J]. *上海交通大学学报*, 2023, 57(6): 659-665.
- SHANG F C, LI C Q, ZHAN K, et al. Application of improved LSTM neural network in time-series prediction of extreme short-term wave[J]. *Journal of Shanghai Jiao Tong University*, 2023, 57(6): 659-665.

(本文编辑 赵娟)