

文章编号: 1006-2467(2023)08-0963-09

DOI: 10.16183/j.cnki.jsjtu.2022.089

# 一种 CNN-LSTM 船舶运动极值预报模型

詹可, 朱仁传

(上海交通大学 船舶海洋与建筑工程学院; 海洋工程国家重点实验室, 上海 200240)

**摘要:** 针对船舶摇荡运动的短期极值预报, 提出一种融合运动频谱信息的滑动窗口方法提取特征数据, 在此基础上构建卷积神经网络(CNN)与长短时记忆(LSTM)网络的组合预报模型, 其中 CNN 模块针对输入数据的局部相关特征, LSTM 模块针对数据的时间维度特征. 对 S175 船进行运动仿真测试, 结果表明, 该模型对未来 1~2 个周期内的运动极值信息预报效果良好, 各项评价指标均明显优于 LSTM 和门控循环单元(GRU)模型, 具有重要的应用价值.

**关键词:** 局部极值; 短期预报; 卷积神经网络; 长短时记忆网络

中图分类号: U 664.82

文献标志码: A

## A CNN-LSTM Ship Motion Extreme Value Prediction Model

ZHAN Ke, ZHU Renchuan

(State Key Laboratory of Ocean Engineering; School of Naval Architecture, Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

**Abstract:** Aimed at the short-term extreme value prediction of ship motion, a sliding window method based on motion spectrum information is proposed to extract feature data, based on which, a series prediction model of convolutional neural networks (CNN) and long short-term memory (LSTM) is built. The CNN module aims at the local correlation characteristics of the input data, and the LSTM module aims at the time dimension characteristics of the data. The simulation test results of S175 ship show that the model has a good prediction effect on the motion extremum information in the next 1 and 2 cycles, and the evaluation indexes are significantly better than those of LSTM and gate recurrent unit (GRU) models, which has an important application value.

**Key words:** local extremum; short-term prediction; convolutional neural network (CNN); long short-term memory (LSTM) networks

船舶在航行时受风、浪、流等复杂外力的作用, 各自由度上均会产生不规则的摇荡运动. 当摇荡幅度过大时, 船舶的航行和作业安全将会受到严峻的挑战. 提前预报船舶未来的摇荡运动可为操作人员提供更多的决策时间, 提高安全性与稳定性.

船舶运动响应的短期预报可以视作一个典型的

时间序列预测(Time Series Forecasting, TSF)问题. 经典的时间序列分析方法, 如自回归模型(Auto Regression Model, ARM)<sup>[1]</sup>、卡尔曼滤波(Kalman Filtering)<sup>[2]</sup>等结构简单, 计算效率高, 但在处理非平稳、非线性的时间序列时效果不佳. 支持向量机(Support Vector Machines, SVM)、人工神经网络

收稿日期: 2022-03-31 修回日期: 2022-05-27 录用日期: 2022-07-27

作者简介: 詹可(1997-), 博士生, 从事船海工程水动力学研究.

通信作者: 朱仁传, 教授, 博士生导师, 电话(Tel.): 021-34204288; E-mail: renchuan@sjtu.edu.cn.

(Artificial Neural Network, ANN)等机器学习模型具有强大的非线性拟合能力,因而在船舶运动预报领域得到广泛重视. Zhou 等<sup>[3]</sup>使用结合经验模态分解的最小二乘支持向量机(Least Squares Support Vector Machines, LS-SVM)预报船舶运动. Pena 等<sup>[4]</sup>通过人工神经网络对船舶横摇运动进行预测. 近年来,循环神经网络(Recurrent Neural Network, RNN)及其变种,尤其是长短期记忆(Long Short-Term Memory, LSTM)网络<sup>[5]</sup>成为了热门模型. RNN 中隐藏层的输入包含了上一时刻隐藏层的输出,能够更好地记忆并学习序列的历史信息,因而更适用于长时间序列的预报, LSTM 则在 RNN 的基础上引入了记忆状态和门控单元,进一步提升了预报效果. 长短期记忆网络等还可与卷积神经网络(Convolutional Neural Networks, CNN)、注意力机制(Attention Mechanism)等相结合. Wang 等<sup>[6]</sup>结合 CNN 与双向 LSTM,建立了基于风速、舵角等多维输入的船舶横摇运动预报模型. Wang 等<sup>[7]</sup>引入时间模式注意力机制(Temporal Pattern Attention, TPA)对双向 LSTM 输出结果进行修正,提升了横摇运动预报效果. Zhang 等<sup>[8]</sup>将多尺度注意力机制与双向 LSTM 结合以预测船舶运动. 除应用新的机器学习模型外,使用小波变换(Wavelet Transform)<sup>[8]</sup>、经验模态分解(Empirical Mode Decomposition, EMD)<sup>[9]</sup>等数据前处理方法也可提升预报精度.

船舶摇荡运动具有明显的周期性,且一般不会出现高频震荡,因而根据序列局部极值点的信息即能较好地还原船舶的运动时历. 从实际需求出发,船舶航行与作业时也更加关注摇荡极值,而当前尚未对此做出深入的研究. 本文结合船舶各自由度摇荡运动频谱捕获序列中的局部极值和周期信息,在此基础上构造 CNN-LSTM 深度学习模型,通过 CNN 的卷积运算进行序列特征提取,再输入 LSTM 模块进行进一步的时间特征学习,最终得到预报结果. 对 S175 船进行仿真实验,结果表明,该模型预报效果优于 LSTM、门控循环单元(Gated Recurrent Unit, GRU)等模型,具有较高的应用价值.

## 1 CNN-LSTM 船舶运动极值预报模型

### 1.1 基于运动响应谱的特征信息提取

对于船舶单个自由度摇荡运动数据构成的一维时间序列  $\mathbf{X} = \{x_i, i = 1, 2, \dots, N\} \in \mathbf{R}^{1 \times N}$ , 采样间隔为  $\Delta t$ , 可采用滑动窗口的形式捕获其局部极值

点,其计算流程如下式:

$$\left. \begin{aligned} \mathbf{C} &= \{c_i, i = 1, 2, \dots, N\} = [\mathbf{C}_1 \ \mathbf{C}_2 \ \mathbf{C}_3] \\ \mathbf{C}_1 &= \{c_i, i = 1, 2, \dots, d\} \\ c_i &= \begin{cases} 1, & x_i = \max(x_1, \dots, x_d) \text{ 且 } x_i > x_{n+1} \\ & \text{或 } \min(x_1, \dots, x_d) \text{ 且 } x_i < x_{n+1} \\ 0, & \text{其他} \end{cases} \\ \mathbf{C}_2 &= \{c_i, i = d+1, \dots, N-d\} \\ c_i &= \begin{cases} 1, & x_i = \max(x_{d+1}, \dots, x_{N-d}) \\ & \text{或 } \min(x_{d+1}, \dots, x_{N-d}) \\ 0, & \text{其他} \end{cases} \\ \mathbf{C}_3 &= \{c_i, i = N-d+1, \dots, N\} \\ c_i &= \begin{cases} 1, & x_i = \max(x_{N-d+1}, \dots, x_N) \text{ 且 } x_i > x_{N-d} \\ & \text{或 } \min(x_{N-d+1}, \dots, x_N) \text{ 且 } x_i < x_{N-d} \\ 0, & \text{其他} \end{cases} \\ \mathbf{P} &= \{i \mid c_i = 1, i = 1, 2, \dots, N\} \\ \mathbf{E} &= \{x_{p_i}, i = 1, 2, \dots, \text{card}(\mathbf{P})\} \\ \mathbf{T} &= \{t_i = p_{i+1} - p_i, i = 1, 2, \dots, \text{card}(\mathbf{P})\} \end{aligned} \right\} \quad (1)$$

式中:  $\mathbf{C} \in \mathbf{R}^{1 \times N}$  为判定向量,判定数据点是否为局部极值点, 0 表示非局部极值点, 1 表示为局部极值点;  $\mathbf{P} \in \mathbf{R}^{1 \times N}$  为位置向量,记录局部极值点在原始序列中的位置;  $\mathbf{E} \in \mathbf{R}^{1 \times \text{card}(\mathbf{P})}$  为极值点向量,记录局部极值点的数值,  $\text{card}(\mathbf{P})$  为  $\mathbf{P}$  中的元素个数;  $\mathbf{T} \in \mathbf{R}^{1 \times \text{card}(\mathbf{P})}$  为周期向量,记录相邻局部极值点的距离;  $d$  为滑动窗口宽度.

对于船舶摇荡运动序列,所取窗口宽度过小时容易受到噪声的干扰;所取窗口宽度过大时,又会造成信息损失. 不同窗口宽度对极值信息提取的效果如图 1 所示. 图中:  $X$  表示位移;  $t$  表示时间.

考虑到船舶运动频谱在较长的时间内保持相对稳定,且包含船舶运动的频域信息,本文选择结合运动响应谱来确定窗口宽度. 各自自由度的运动响应谱通过 Welch 法<sup>[10]</sup>计算,其基本步骤如下.

对于长度为  $N$  的序列  $X$ ,将其分为  $L$  个小段,分别记作  $l_i (i = 1, 2, \dots, L)$ , 每个小段长度为  $M$ , 相邻小段间重叠长度为  $M/2$ , 则段数

$$L = \frac{2N - M}{M} \quad (2)$$

对每个小段添加窗函数  $w(m)$  后作傅里叶变换:

$$F_i(e^{j\omega}) = \sum_{m=0}^{M-1} l_i(m) w(m) e^{-j\omega m} \quad (3)$$

式中:  $i = 1, 2, \dots, L$ ;  $j$  为虚数单位;  $\omega$  为频域中的对应频率.

窗函数一般取 Hanning 窗,其表达式为




图 1 不同窗口宽度对极值提取效果的影响

Fig. 1 Effect of different window widths on extreme value extraction

$$\omega(m) = \frac{1}{2} \left( 1 - \cos \frac{2\pi m}{M-1} \right) \tag{4}$$

式中： $m = 0, 1, \dots, M-1$ .

计算各小段功率谱的均值作为最终结果：

$$S(\omega) = \frac{1}{L} \sum_{i=1}^L \frac{1}{U} |F_i(e^{j\omega})|^2 \tag{5}$$

式中： $U = \sum_{m=0}^{M-1} \omega^2(m)$ ，代表数据窗中所包含的能量。在计算得功率谱  $S$  之后，窗口宽度由下式确定：

$$\left. \begin{aligned} \omega_p &= \{ \omega_i \mid S(\omega_i) = \max S \} \\ d &= \lceil \pi / (\omega_p \Delta t) \rceil \end{aligned} \right\} \tag{6}$$

式中： $\lceil \cdot \rceil$ 为取整函数。

1.2 卷积神经网络

卷积神经网络是一类以卷积运算为核心的深度前馈神经网络。完整的二维卷积神经网络通常包括输入层、卷积层、池化层、全连接层、输出层等模块<sup>[11]</sup>。卷积神经网络对数据的特征提取主要依赖于卷积层中的卷积核，其计算过程<sup>[12]</sup>为

$$y_j^k = f \left( k \sum_{i \in C_j} x_i^{k-1} * u_{ij}^k + b_j^k \right) \tag{7}$$

式中： $x_i^{k-1}$ 为第 $k-1$ 层的第 $i$ 个特征图的输出值； $u_{ij}^k$ 为第 $k$ 层第 $j$ 个特征图与第 $k-1$ 层第 $i$ 个特征图之间的卷积核； $b_j^k$ 为第 $k$ 层的第 $j$ 个特征图的偏置； $C_j$ 为输入的特征图的集合； $y_j^k$ 为第 $k$ 层的第 $j$ 个特征图的输出值； $*$ 表示卷积计算； $f(\cdot)$ 为激活函数，通常取 ReLU 函数或者 sigmoid 函数。

如图 2 所示，卷积核（也称为过滤器）通过逐步平移的方式扫描二维数据并进行卷积运算，从而提取数据特征，其中蓝色区域为卷积核计算区域，黄色部分为卷积核，橙色部分为卷积核计算结果。为充分提取特征信息，一般需要设置多个卷积核。

池化层采用类似的逐步平移方式扫描卷积层输出的特征图，依次捕获过滤器内的最大值，从而缩减




图 2 卷积核计算过程

Fig. 2 Convolution kernel calculation process

数据规模，降低模型复杂度。通过多个卷积层和池化层的交替堆叠，可以更好地提取数据的深层特征。

1.3 长短时记忆网络

长短时记忆网络是循环神经网络的一个变种，该网络能有效解决传统模型训练过程中的梯度消失问题<sup>[13]</sup>，适用于长时间序列的分析和预测。与标准的 RNN 网络相比，LSTM 在隐藏层神经节点中增加了一个记忆状态单元来存储过去的信息，并用 3 种门控结构（输入门、遗忘门、输出门）来控制历史信息的遗忘与更新。LSTM 隐藏层神经元的基本结构<sup>[14]</sup>如图 3 所示。

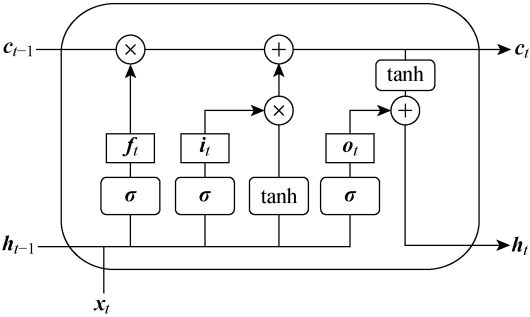


图 3 LSTM 单元结构

Fig. 3 LSTM neural network

LSTM 网络根据如下规则<sup>[6]</sup>更新时刻状态:

$$\mathbf{g}_i = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1} \mathbf{x}_t] + \mathbf{b}_i) \tag{8}$$

$$\mathbf{g}_f = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1} \mathbf{x}_t] + \mathbf{b}_f) \tag{9}$$

$$\mathbf{g}_o = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1} \mathbf{x}_t] + \mathbf{b}_o) \tag{10}$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1} \mathbf{x}_t] + \mathbf{b}_c) \tag{11}$$

$$\mathbf{c}_t = \mathbf{g}_i * \tilde{\mathbf{c}}_t + \mathbf{g}_f * \mathbf{c}_{t-1} \tag{12}$$

$$\mathbf{h}_t = \mathbf{g}_o * \tanh \mathbf{c}_t \tag{13}$$

式中： $\mathbf{x}_t$  为  $t$  时刻的输入向量； $\mathbf{h}_t$  为  $t$  时刻的隐藏状态向量； $\mathbf{c}_t$  为  $t$  时刻的记忆状态向量； $\mathbf{g}_i$ 、 $\mathbf{g}_f$ 、 $\mathbf{g}_o$  分别代表输入门、遗忘门和输出门； $\mathbf{W}_i$ 、 $\mathbf{W}_f$ 、 $\mathbf{W}_o$ 、 $\mathbf{W}_c$  分别代表各连接层的权重矩阵； $\mathbf{b}_i$ 、 $\mathbf{b}_f$ 、 $\mathbf{b}_o$ 、 $\mathbf{b}_c$  分别代表各连接层的偏置项； $\sigma$  为 sigmoid 函数. 当前时刻的输入  $\mathbf{x}_t$ ，上一时刻的隐藏状态  $\mathbf{h}_{t-1}$  以及上一时刻的记忆状态  $\mathbf{c}_{t-1}$  依次通过上述 3 个门控单元  $\mathbf{g}_i$ 、 $\mathbf{g}_f$  和  $\mathbf{g}_o$  进行计算，得到当前时刻的隐藏状态  $\mathbf{h}_t$  和记忆状态  $\mathbf{c}_t$ ，并作为下一时间步的输入继续推进，门控单元内的权重矩阵、隐藏状态和记忆状态也随之不断更新，从而实现对序列信息的训练学习.

1.4 CNN-LSTM 船舶运动极值预报模型

为充分发掘船舶运动的各个模态间可能存在潜在的映射关系，本文构造了基于多维数据输入的 CNN-LSTM 预报模型，如图 4 所示. 图中：ReLU 为激活函数，表达式  $f(x) = \max\{0, x\}$ ；Dropout 层为随机失活层，通过随机使一定比例神经元失活的

方式防止出现参数过拟合. 在对一系列超参数组进行初步测试后，选取其中表现最优的一组作为模型参数，如表 1 所示.

表 1 CNN-LSTM 模型具体参数  
Tab. 1 Parameters of CNN-LSTM model

层	核数	尺寸	步长	隐藏节点数	失活率
卷积层 1	96	(2, 1)	1	—	—
池化层 1	—	(3, 1)	1	—	—
卷积层 2	64	(1, 1)	1	—	—
池化层 2	—	—	—	—	—
LSTM 层 1	—	—	—	200	—
LSTM 层 2	—	—	—	150	—
LSTM 层 3	—	—	—	100	—
Dropout 层	—	—	—	—	0.5

完整的模型训练及预报流程如图 5 所示. 对于获取的垂荡、横摇、纵摇、首摇 4 自由度运动时间序列  $\mathbf{X}^n = \{\mathbf{x}_i^n, i = 1, 2, \dots, N_n\} \in \mathbf{R}^{1 \times N_n}, n = 3, 4, 5, 6$ , 其中  $n$  为自由度编号. 采用后文数据集生成方法进行特征信息提取，分别转化为极值信息序列  $\mathbf{E}^n = \{\mathbf{e}_i^n, i = 1, 2, \dots, M_n\} \in \mathbf{R}^{1 \times M_n}$  和周期信息序列  $\mathbf{T}^n = \{\mathbf{t}_i^n, i = 1, 2, \dots, K_n\} \in \mathbf{R}^{1 \times K_n}$ . 借鉴自然语言处理(Natural Language Processing, NLP)中的

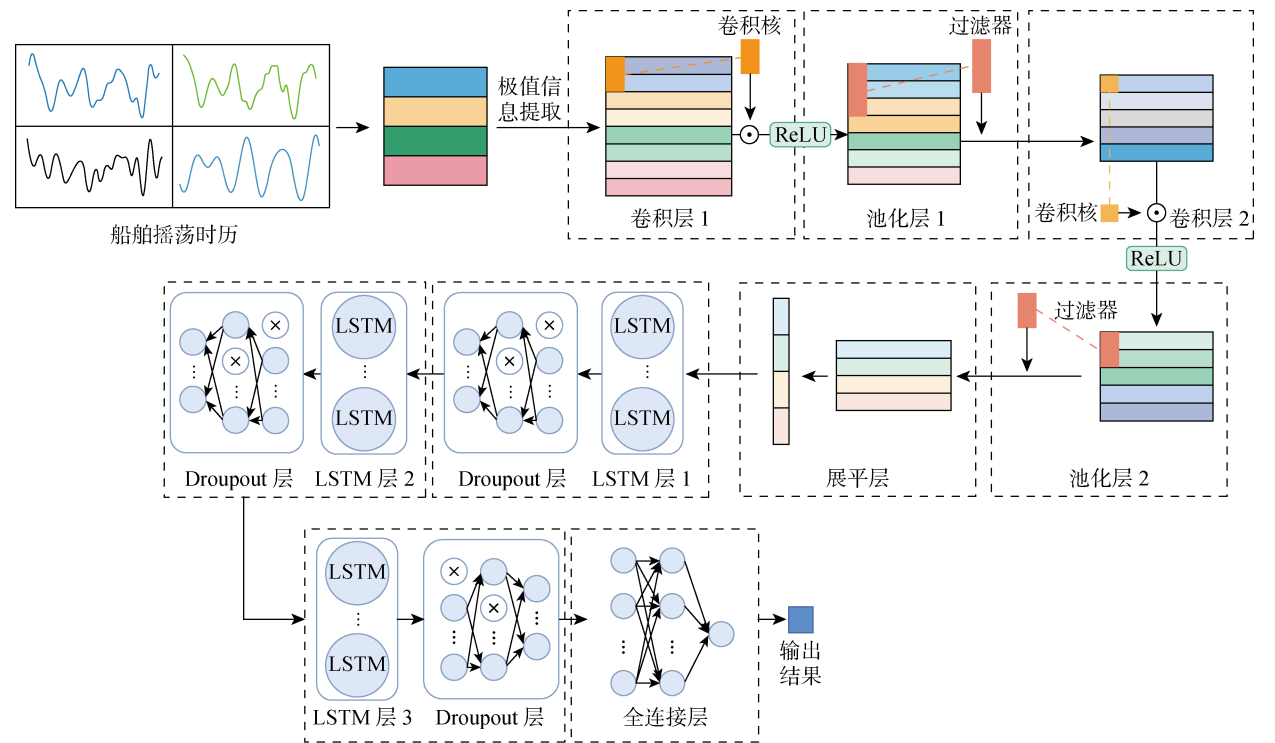


图 4 CNN-LSTM 预报模型结构

Fig. 4 Structure of CNN-LSTM model

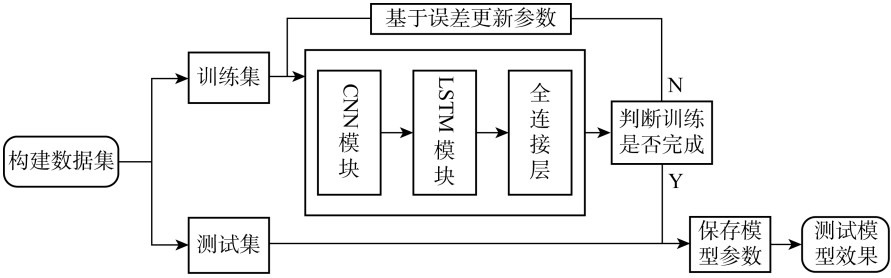


图 5 CNN-LSTM 预报模型计算流程

Fig. 5 Calculation process of CNN-LSTM model

做法,通过在较短序列的前端填充 0 元素的方式将各序列长度统一为  $N = \max\{M_n, K_n\}$ , 分别记为  $\tilde{\mathbf{E}}^n \in \mathbf{R}^{1 \times N}$  和  $\tilde{\mathbf{T}}^n \in \mathbf{R}^{1 \times N}$ . 将长度统一后的各序列组装成  $8 \times N$  的二维矩阵  $\mathbf{I} = \{\tilde{\mathbf{E}}^T, \tilde{\mathbf{T}}^T\}^T \in \mathbf{R}^{8 \times N}$  作为模型数据集,其中  $\tilde{\mathbf{E}}^T = \{\tilde{\mathbf{E}}^{nT}, n=3, 4, 5, 6\} \in \mathbf{R}^{N \times 4}$ ,  $\tilde{\mathbf{T}}^T = \{\tilde{\mathbf{T}}^{nT}, n=3, 4, 5, 6\} \in \mathbf{R}^{N \times 4}$ . 为完成模型的训练及预报,需要设置依赖步数  $l$ ,并据此对数据集进行切割,即输入矩阵  $\mathbf{I}$  中第  $m$  列到第  $m+l$  列的数据,对垂荡、横摇、纵摇 3 个模态分别输出未来第  $k$  个极值点  $\hat{e}_{m+l+k}^n, n=3, 4, 5$ . 模型预报时,输入数据通过 2 组卷积层和池化层进行特征提取,输出结果展平后再依次通过 3 层 LSTM 层进行进一步的时间特征学习,最终由全连接层输出未来第  $k$  个极值点  $\hat{e}_{N+k}^n, k$  为向后预报的步数.

本文采用误差反传算法训练模型参数,损失函数取均方误差 (Mean Squared Error, MSE),优化器为 Adam,初始学习率为 0.001,迭代总数为 1 200 次,训练批量大小为 10. 选取数据集的前 95% 为训练集,后 5% 为测试集. 依赖步数  $l=30$ ,向后预报步数  $k$  分别取 1, 2.

## 2 S175 船运动预报结果与分析

### 2.1 数据集生成

本文以 S175 集装箱船为对象,其主尺度参数

为:船长 175 m,船宽 25.4 m,吃水 9.5 m,排水体积 23 680  $\text{m}^3$ ,方形系数 0.572. 通过海洋系统模拟器 (Marine Systems Simulator, MSS) 软件<sup>[15]</sup> 计算生成其迎浪 0 航速下垂荡、横摇、纵摇、首摇 4 个自由度的摇荡时间序列,分别记为  $X^3$ 、 $X^4$ 、 $X^5$ 、 $X^6$ ,以船舶及海上平台作业时最为关注的  $X^3$ 、 $X^4$ 、 $X^5$  为 3 个目标维度. 波浪基于 Jonswap 谱生成,其表达式<sup>[16]</sup>如下:

$$\left. \begin{aligned} S(\omega, \theta) &= S(\omega)D(\omega, \theta) \\ S(\omega) &= \frac{114}{T_1^4} \frac{h_{1/3}^2}{\omega^5} \exp\left(-\frac{691}{T_1^4 \omega^4}\right) \times \\ &\quad 3.3 \exp\left[-\left(\frac{0.206\omega T_1 - 1}{\sqrt{2}\sigma_p}\right)^2\right] \\ D(\omega, \theta) &= \frac{2}{\pi} \cos^2 \theta, \quad |\theta| \leq \frac{\pi}{2} \\ \sigma_p &= \begin{cases} 0.07, & \omega \leq \omega_p \\ 0.09, & \omega > \omega_p \end{cases} \end{aligned} \right\} \quad (14)$$

式中:  $h_{1/3}$  为有义波高;  $T_1$  为特征周期;  $\omega_p$  为谱峰频率;  $\theta$  为成分波与平均浪向之间的夹角. 波浪相关参数为:有义波高 5 m,特征周期 9.7 m,谱峰频率 0.6 rad/s,平均浪向 180°,频率区间数 50,浪向区间数 20. 为保证预报结果的一般性,该参数为随机选取,后续使用的船舶运动数据均基于该组参数生成.

计算生成 7 200 s 的四自由度摇荡时间序列,  $\Delta t=50$  ms,共计 144 001 个数据点. 各摇荡序列对应的响应谱如图 6 所示,图中  $f$  为波浪频率. 由式 (6)




图 6 四自由度运动响应谱

Fig. 6 Motion response spectrum of four degrees of freedom

计算得窗口宽度  $d_3 = 110$ ,  $d_4 = 110$ ,  $d_5 = 105$ ,  $d_6 = 100$ , 再由式(1)进行极值信息提取, 并通过填充操作最终获得尺寸为  $8 \times 1\,343$  的二维数据集  $\mathbf{I} = \{I_{ij}, i=1, 2, \dots, 8, j=1, 2, \dots, 1\,343\} = \{\tilde{\mathbf{E}}^{3T},$

$\tilde{\mathbf{E}}^{4T}, \tilde{\mathbf{E}}^{5T}, \tilde{\mathbf{E}}^{6T}, \tilde{\mathbf{T}}^{3T}, \tilde{\mathbf{T}}^{4T}, \tilde{\mathbf{T}}^{5T}, \tilde{\mathbf{T}}^{6T}\}^T \in \mathbf{R}^{8 \times 1\,343}$ . 图 7 展示了  $\mathbf{I}$  中各行数据的局部图像. 图中:  $E$  表示极值点;  $D$  表示相邻极值点间的数据点个数. 使用 2.4 节所述模型及相关参数对该数据进行训练及预报.

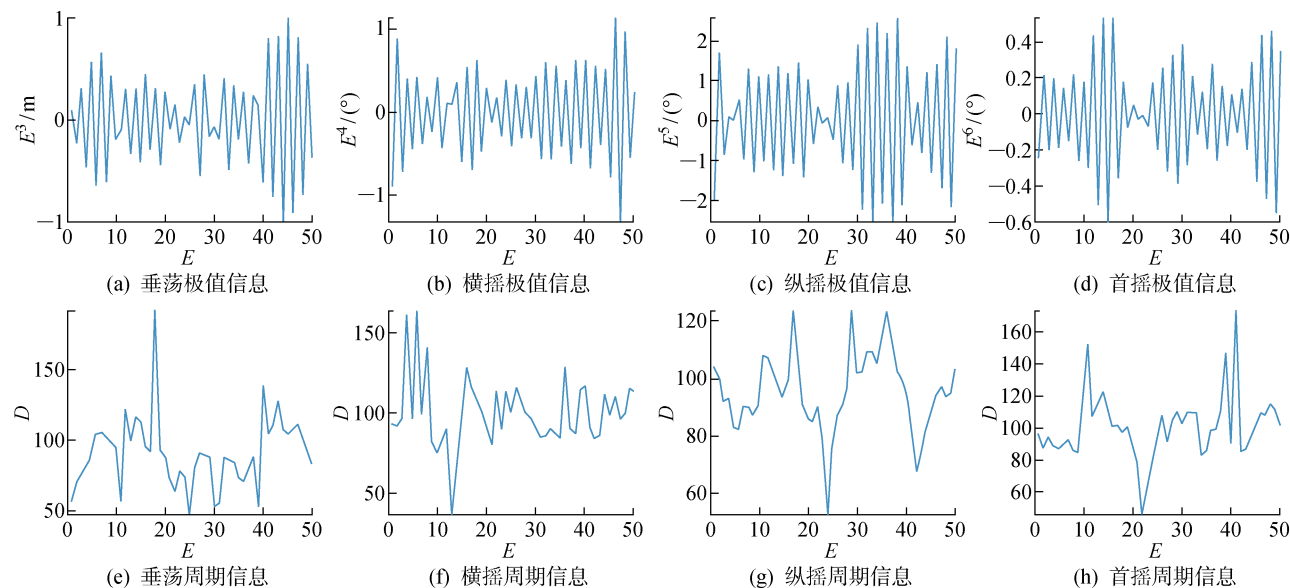


图 7 数据集局部图像(前 50 个点)

Fig. 7 Image of Local dataset (top 50 points)

## 2.2 模型评价

**2.2.1 模型评价指标** 为分析模型的预报效果, 本文选取平均绝对误差 (Mean Absolute Error,  $e_{MAE}$ )、均方误差 (Mean Squared Error,  $e_{MSE}$ )、均方根误差 (Root Mean Squared Error,  $e_{RMSE}$ ) 和相关系数 (Correlation Coefficient,  $r$ ) 4 个指标进行评估. 以上均为时间序列预测领域的通用评价指标, 具有一定的普适性. 各指标由下式计算:

$$e_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (15)$$

$$e_{MSE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|^2 \quad (16)$$

$$e_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|^2} \quad (17)$$

$$r = \frac{S_{y\hat{y}}}{S_y S_{\hat{y}}} = \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (18)$$

**2.2.2 对照模型** 为进一步验证预报性能, 本文设置了两种对照模型. 模型 1 的基础框架为前述 CNN-LSTM 模型的 LSTM 部分, 模型 2 在模型 1 的基础上将 LSTM 单元替换为 GRU<sup>[17]</sup>. GRU 将 LSTM 的输入门和遗忘门合并更新门, 其待训练参

数少于 LSTM.

## 2.3 仿真结果与分析

分别使用上述 CNN-LSTM、LSTM、GRU 模型对 S175 船在波浪中 3 个自由度的摇荡运动进行极值信息预报. 各模型向后预报一个极值时的结果如图 8 所示. 采用 2.2.1 中的评价指标评估各模型在测试集上的预报误差, 结果如表 2 所示.

本文提出的 CNN-LSTM 模型在各项误差指标上都优于 LSTM 和 GRU 模型, 以 MSE 为标准, 3 个自由度下的预报效果比 LSTM 模型分别提升了 55.5%、51.1% 和 47.4%, 比 GRU 模型分别提升了 56.9%、47.1% 和 47.2%. 以 MAE 为标准, 3 个自由度下的预报效果比 LSTM 模型分别提升了 32.4%、22.3% 和 27.1%, 比 GRU 模型分别提升了 33.5%、21.5% 和 27.1%. 从图像上看, CNN-LSTM 模型的预报幅值普遍比其余两种模型更接近真实值; 而在序列出现非平稳波动处, LSTM 和 GRU 模型的预报结果偏差较大, 而 CNN-LSTM 模型仍能较好地给出预报结果. 可见, CNN-LSTM 模型中卷积层和池化层对数据特征信息的提取显著提升了预报性能, 该模型能够基于历史数据较为精确地预报下一极值点的信息.

CNN-LSTM 模型提前 2 步的极值预报结果如图 9 所示. 提前 2 步预报的误差情况如表 3 所示.



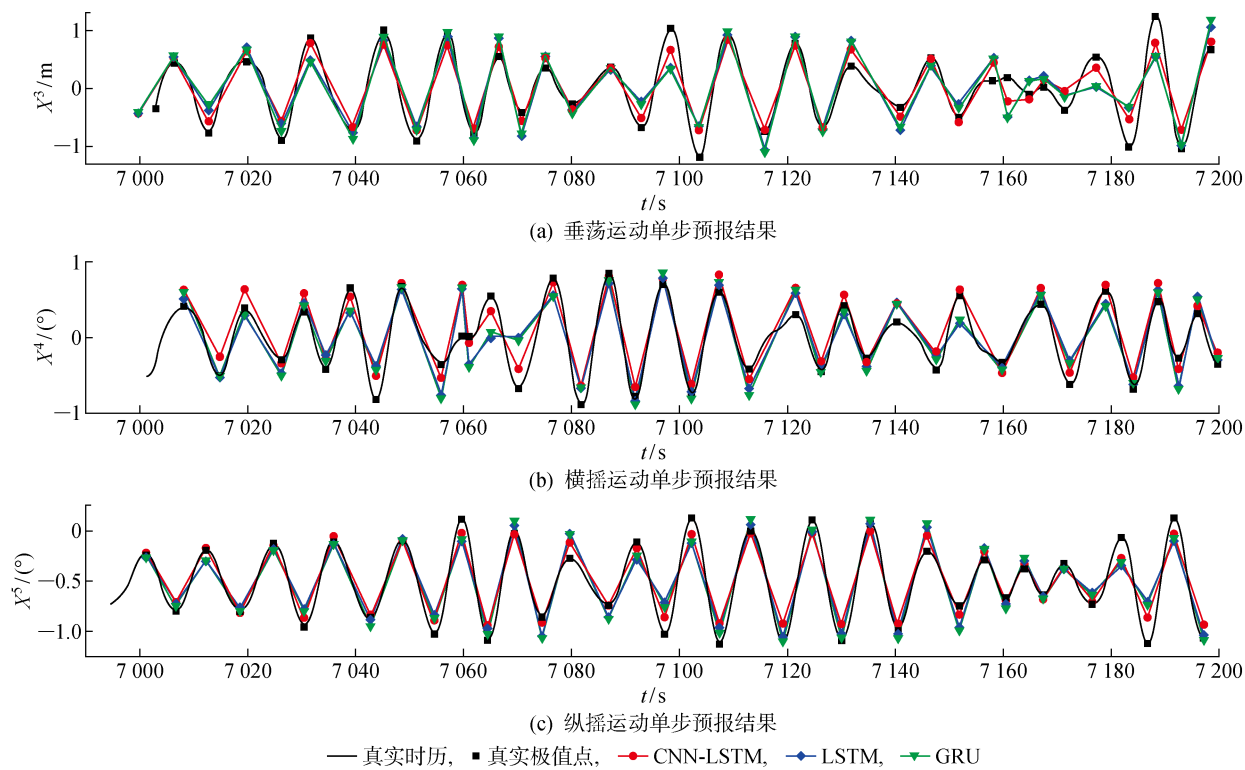


图 8 各模型单步预报结果

Fig. 8 Results of single step prediction




图 9 CNN-LSTM 模型多步预报结果

Fig. 9 Results of multi-step prediction

表 2 各模型单步预报误差  
Tab. 2 Single step prediction error

模型	垂荡				横摇				纵摇			
	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$
	$m^2$	m	m		$(^{\circ})^2$	$(^{\circ})$	$(^{\circ})$		$(^{\circ})^2$	$(^{\circ})$	$(^{\circ})$	
CNN-LSTM	0.067 2	0.259 3	0.215 1	0.963 8	0.038 2	0.195 3	0.166 5	0.953 4	0.190 8	0.436 8	0.355 5	0.975 1
LSTM	0.151 1	0.388 7	0.318 3	0.831 8	0.078 2	0.269 9	0.214 3	0.873 1	0.362 5	0.602 1	0.487 0	0.937 2
GRU	0.155 8	0.394 7	0.323 7	0.829 9	0.072 2	0.208 8	0.212 0	0.874 1	0.361 7	0.601 4	0.488 0	0.937 3

表 3 CNN-LSTM 模型多步预报误差  
Tab. 3 Multi-step prediction error

预报步数	垂荡				横摇				纵摇			
	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$	$e_{MSE}/$	$e_{RMSE}/$	$e_{MAE}/$	$r$
	$m^2$	m	m		$(^{\circ})^2$	$(^{\circ})$	$(^{\circ})$		$(^{\circ})^2$	$(^{\circ})$	$(^{\circ})$	
提前 2 步	0.177 2	0.421 0	0.345 4	0.818 0	0.067 0	0.258 9	0.203 6	0.900 7	0.407 2	0.638 2	0.518 9	0.946 1

可见,CNN-LSTM 模型的多步预报精度有所下降,同时预报结果出现了一定的滞后性.这是由于序列本身具有非平稳非线性的特点,随着预报步数的增加,输入值与预报值间的潜在规律更加复杂,训练难度也因此上升.图 10 所示为各自由度预报结果

与实际观测值间的相关性分析.其中, $X_p$  表示预测值, $X_r$  表示真实值.可见,预报结果的变化趋势仍与实际情况吻合较好,提前 2 步的 3 自由度预报值与实际值的平均相关系数分别为 81.8%、90.7%和 94.6%,能够满足实际需求.

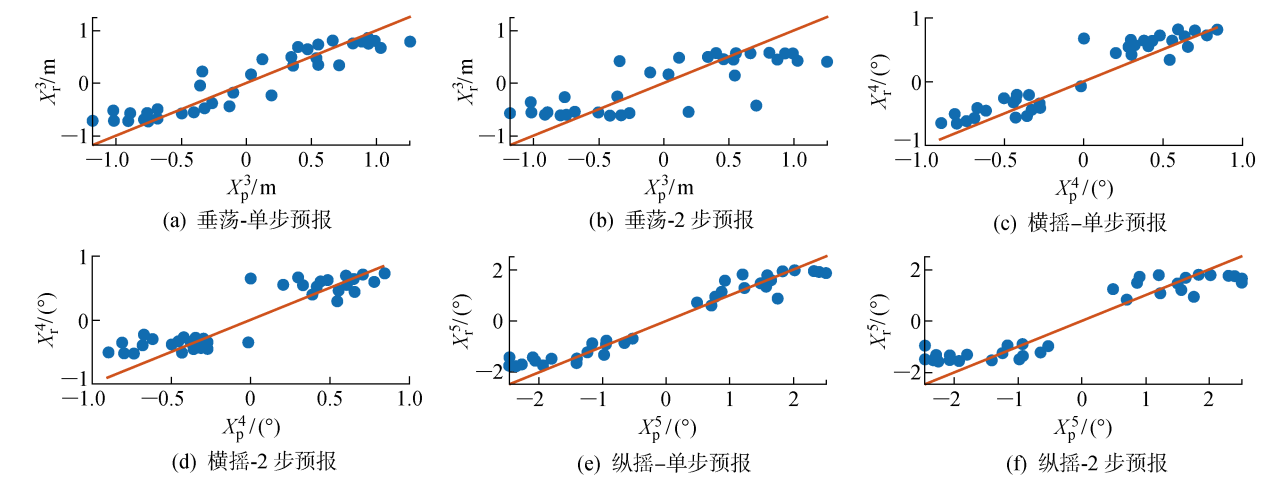


图 10 预报结果与实际值的相关性分析  
Fig. 10 Correlation analysis of prediction results and actual values

3 结论

以船舶摇荡运动的极值信息为预报目标,以船舶 4 个自由度的运动时间序列为原始数据,构造了一种 CNN-LSTM 组合预报模型.针对 S175 船的验证结果表明,该模型在单步预报时精度良好,各项误差指标相较 LSTM 和 GRU 模型均有明显提升,垂荡、横摇、纵摇 3 个自由度下的 MSE 较 LSTM 模型分别提升了 55.5%、51.1%和 47.4%,较 GRU 模

型分别提升了 56.9%、47.1%和 47.2%;MAE 较 LSTM 模型分别提升了 32.4%、22.3%和 27.1%,较 GRU 模型分别提升了 33.5%、21.5%和 27.1%.在多步预报时误差指标略有下降,但预报趋势仍能与实际值保持吻合,提前 2 步的 3 自由度预报值与实际值的平均相关系数分别为 81.8%、90.7%和 94.6%.

本文提出的预报模型具有以下优点:① 结合船舶运动响应谱进行数据前处理,有效提取了船舶运



动极值信息,同时抑制了高频噪声的影响;② 通过 CNN 模块发掘学习各维度数据间的潜在联系,充分利用了已知信息,并提高了预报精度;③ 模型预报效果良好,仿真实验表明该模型能够准确预报未来 1~2 个周期内船舶运动的极值信息,且预测指标明显优于对照模型.在此基础上,未来可进一步探究该模型针对实测复杂海况下的预报效果,并实现完整的在线预报流程.该工作对于诸如舰载机起降、海上平台安装等场景具有重要应用价值,同时也可作为波浪信息预报等时间序列预测问题提供参考.

## 参考文献:

- [1] 喻元根,马雪泉,季盛.基于 AR 的船舶运动极短期预报摇摆平台试验[J].上海船舶运输科学研究所学报,2016,39(4): 4-7.  
YU Yuangen, MA Xuequan, JI Sheng. Short time prediction of ship motion based on AR model and stewart platform experiment[J]. **Journal of Shanghai Ship and Shipping Research Institute**, 2016, 39(4): 4-7.
- [2] 范海平.基于卡尔曼滤波技术的船舶横摇预测方法研究[D].哈尔滨:哈尔滨工程大学,2008.  
FAN Haiping. Study on the prediction and estimation of ship roll motion based on Kalman filter[D]. Harbin: Harbin Engineering University, 2008.
- [3] ZHOU B, SHI A. Empirical mode decomposition based LSSVM for ship motion prediction[C]//**International Symposium on Neural Networks**. Berlin, Heidelberg, Germany: Springer, 2013.
- [4] PENA F L, GONZALEZ M M, CASAS V D, *et al.* An ANN based system for forecasting ship roll motion[C]//**Computational Intelligence and Virtual Environments for Measurement Systems and Applications**. Milan, Italy: IEEE Instrumentation & Measurement Magazine, 2013.
- [5] HOCHREITER S, SCHMIDHUBER R A, *et al.* Long short-term memory[J]. **Neural Computation**, 1997, 9: 1735-1780.
- [6] WANG Y, WANG H, ZHOU B, *et al.* Multi-dimensional prediction method based on Bi-LSTMC for ship roll[J]. **Ocean Engineering**, 2021, 242: 110106.
- [7] WANG Y, WANG H, ZOU D, *et al.* Ship roll prediction algorithm based on Bi-LSTM-TPA combined model[J]. **Journal of Marine Science and Engineering**, 2021, 9(4): 387-1-16.
- [8] ZHANG T, ZHENG X Q, LIU M X. Multiscale attention-based LSTM for ship motion prediction[J]. **Ocean Engineering**, 2021, 230(13): 109066.
- [9] 张彪,彭秀艳,高杰.基于 ELM-EMD-LSTM 组合模型的船舶运动姿态预测[J].船舶力学,2020,24(11): 1413-1421.  
ZHANG Biao, PENG Xiuyan, GAO Jie. Ship motion attitude prediction based on ELM-EMD-LSTM integrated model[J]. **Journal of Ship Mechanics**, 2020, 24(11): 1413-1421.
- [10] STOICA P, MOSES R. Spectral analysis of signals [M]. New Jersey, USA: Prentice Hall, 2005.
- [11] KETKAR N, MOOLAYIL J. Deep Learning with Python[M]. Berkeley, USA: Apress, 2021: 197-242.
- [12] 赵建利,白格平,李英俊,等.基于 CNN-LSTM 的短期风电功率预测[J].自动化仪表,2020,41(5): 37-41.  
ZHAO Jianli, BAI Geping, LI Yingjun, *et al.* Short-term wind power prediction based on CNN-LSTM [J]. **Process Automation Instrumentation**, 2020, 41(5): 37-41.
- [13] 王国栋.基于 LSTM 的舰船运动姿态短期预测及仿真研究[D].镇江:江苏科技大学,2017.  
WANG Guodong. Short-term prediction and simulation of ship's motion based on LSTM[D]. Zhenjiang: Jiangsu University of Science and Technology, 2017.
- [14] 刘秀丽,徐小力.基于特征金字塔卷积循环神经网络的故障诊断方法[J].上海交通大学学报,2022,56(2): 182-190.  
LIU Xiuli, XU Xiaoli. Fault diagnosis method based on feature pyramid CRNN network[J]. **Journal of Shanghai Jiao Tong University**, 2022, 56(2): 182-190.
- [15] TRISTAN P, FOSSEN T I. A MATLAB toolbox for parametric identification of radiation-force models of ships and offshore structures[J]. **Modeling, Identification and Control**, 2009, 30(1): 1-15.
- [16] 朱仁传,缪国平.船舶在波浪上的运动理论[M].上海:上海交通大学出版社,2019: 185-186.  
ZHU Renchuan, MIAO Guoping. The theory of ship motion in waves [M]. Shanghai: Shanghai Jiao Tong University Press, 2019: 185-186.
- [17] MWL A, DYX A, JING G A, *et al.* A hybrid approach for forecasting ship motion using CNN-GRU-AM and GCWOA[J]. **Applied Soft Computing**, 2022, 114: 108084.

(本文编辑:王一凡)