

DOI:10.11918/202307085

基于深度学习的海工平台运动预测

薛佳帆¹, 张航维¹, 何广华^{1,2,3}, 姜泽成²

(1. 哈尔滨工业大学(威海)海洋工程学院, 山东 威海 264209; 2. 哈尔滨工业大学机电工程学院, 哈尔滨 150001; 3. 山东船舶技术研究院, 山东 威海 264209)

摘要: 为提高海上作业装备的安全性能, 实现海上结构物运动的实时预报, 本研究利用了一种卷积神经网络(convolutional neural network, CNN)方法与长短期记忆(long short-term memory, LSTM)方法混合的深度学习模型用于运动预测, 该混合模型运用CNN提取运动数据的特征, 采用LSTM学习提取出的特征间的时间关系, 并结合贝叶斯(Bayesian)优化算法优化混合模型的超参数。首先, 对海工平台进行数值仿真, 将得到的纵荡运动数据作为实验数据。其次, 将数据集划分为训练集、验证集与测试集, 利用训练集与验证集进行训练与验证, 获得6、12、18 s运动最优预测模型, 并利用测试集与LSTM模型进行比较。结果表明: 混合模型在6、12、18 s预测上相比于LSTM等模型, 预测精度可以提高15%~30%。除此之外, 本研究还分别探究了预测精度与输入时长、预测时长之间的关系, 结果显示预测精度受输入时长的影响较小, 但随着预测时长的增加近似呈线性下降趋势。最后结合训练耗时证明了混合模型相比于LSTM等模型更具有优势。

关键词: 贝叶斯优化; 自动机器学习; 运动预测; CNN; LSTM

中图分类号: TP391.9

文献标志码: A

文章编号: 0367-6234(2024)08-0163-08

Motion prediction of offshore platforms based on deep learning

XUE Jiafan¹, ZHANG Hangwei¹, HE Guanghua^{1,2,3}, JIANG Zecheng²

(1. School of Ocean Engineering, Harbin Institute of Technology (Weihai), Weihai 264209, Shandong, China;

2. School of Mechatronics Engineering, Harbin Institute of Technology, Harbin 150001, China;

3. Shandong Institute of Shipbuilding Technology, Weihai 264209, Shandong, China)

Abstract: To improve the safety performance of offshore operation equipment and realize the real-time prediction of motion of offshore structures, a hybrid deep learning model combining convolutional neural network (CNN) and long short-term memory (LSTM) methods is used in this study. The hybrid model extracts the features from motion data by CNN, and utilizes LSTM to learn the temporal relationship among the extracted features. Additionally, Bayesian optimization algorithm is introduced to optimize the hyperparameters of the hybrid model. Firstly, the numerical simulation of the offshore platform is carried out, and the obtained surge motion data is used as experimental data. Secondly, the experimental dataset is divided into training set, verification set and test set. The training and verification set are used for model training and validation to obtain the optimal prediction models for 6 s, 12 s and 18 s of motion. The performance of the developed models is compared with that of the LSTM model using the testing set. The results show that the hybrid model, compared with the LSTM model, can improve the prediction accuracy by 15% to 30% for 6 s, 12 s and 18 s predictions. Furthermore, this study also investigates the relationship between prediction accuracy and input duration as well as prediction duration. The results suggest that the input duration has a minimal impact on the prediction accuracy, while the prediction accuracy shows a linear downward trend with the increase of the prediction duration. Finally, combined with the training time, the hybrid model in this paper demonstrates advantages over LSTM and other models.

Keywords: Bayesian optimization; automatic machine learning; motion prediction; CNN; LSTM

近年来,随着中国海洋资源的大力开发,海工平台得到蓬勃发展。波浪引起的海工平台运动严重影响了海上作业的营运性能和安全性能,甚至导致事故发生^[1]。因此,开发一种准确的、实时的运动预

测方法十分重要。

关于海工平台的运动预测方法主要分为:水动力学方法、统计回归方法、智能学习方法。其中经典的水动力学预测方法有势流方法与黏流方法^[2]。

收稿日期: 2023-07-31; 录用日期: 2023-09-20; 网络首发日期: 2024-06-29

网络首发地址: <https://link.cnki.net/urlid/23.1235.T.20240628.0928.004>

基金项目: 山东省泰山学者工程专项经费(tsqn201909172); 山东省高等学校青年创新团队科技计划(2019KJN003)

作者简介: 薛佳帆(2000—),男,硕士研究生;何广华(1980—),男,教授,博士生导师

通信作者: 何广华, ghhe@hitwh.edu.cn

虽然水动力学方法具有严谨的数学和物理推导过程,但其求解时长往往难以满足实时响应的需求,且建模和求解过程复杂。统计回归方法的优势在于不需要建立水动力学模型,只需利用运动数据即可完成预测,如:自回归^[3-4]、支持向量回归^[5]、高斯过程回归已被应用到船舶运动响应的预测上。但是由于统计回归方法是单步预测方法,对于多步预测存在迭代误差,限制了其应用范围。智能学习方法主要指神经网络学习方法,基于其建模原理,该方法具有无限趋近于任何一个非线性函数的能力。相比于水动力学方法与统计回归方法,反向传播(back propagation, BP)神经网络^[6]、径向基函数(radial basis function, RBF)神经网络^[7]的引入使预测效果更加准确。但以上两种一般的神经网络方法只搭建了简单的输入与输出之间的映射关系,没有考虑不同的输入时间点对于预测结果的影响程度。因此,研究人员^[8]进一步将长短期记忆(long short-term memory, LSTM)这一特殊的神经网络模型引入到海上结构物的运动预测中,通过引入 3 个门控开关与记忆细胞,自适应记忆不同时间点输入数据的时间信息,从而达到更好预测效果。此外卷积神经网络(convolutional neural network, CNN)和 Transformer 作为一种特殊的神经网络,在图像处理、自然语言处理^[9-10]领域也有着很广泛的应用,具有强大的特征提取能力。神经网络方法的预测能力具有优越性,但其学习和预测能力对神经网络超参数的选取较为敏感。在以往的工作中,各种研究把参数优化聚焦在神经网络训练过程中的权值优化^[11]上,而对于超参数的选取大都是采用人工调优、网格搜索或随机搜索的方法。其中人工调优方法需要模型的先验知识,而网格搜索和随机搜索效率低下,不属于智能寻优算法,对此本文利用自动机器学习领域中的智能寻优算法即贝叶斯^[12](Bayesian)寻优来解决超参数的选取问题。本文设计了一种 CNN 与 LSTM 相结合的混合方法,旨在利用 CNN 的特征提取能力与 LSTM 的时序建模能力构建预测模型,并将其应用于海工平台的运动预测中。经实验对比,该混合模型比 LSTM 等模型具有更强预测能力。

1 模型结构与相关理论

1.1 卷积神经网络(CNN)

卷积神经网络已广泛应用于图像识别、图像处理^[13]以及大规模的视觉识别等方面。图 1 给出了一维卷积神经网络的结构与工作原理。

从图 1 中可以看出一维卷积神经网络主要由输入层、卷积层、池化层以及全连接层(输出层)组成。

其中输入层有输入向量 $X \in \mathbf{R}^{m \times 1}$,卷积层有 n 个卷积核,其中 $K_i \in \mathbf{R}^{5 \times 1}$ 为第 i 个卷积核。将输入向量 X 输入卷积层后,对一维向量进行卷积操作,该操作过程使用每一个卷积核对输入向量进行滑动卷积操作,每次滑动一个时间步长,得到卷积输出,图 1 中所示 $C_j \in \mathbf{R}^{m-4 \times 1}$ 即为第 j 个卷积核的卷积输出,卷积输出的个数为 n 。在经过卷积操作后将卷积输出输入到池化层,通过最大池化操作,经过最大池化层后得到 n 个输出,其中 M_k 即为第 k 个池化操作的输出。最后,通过全连接层获得整个卷积神经网络的输出 $Y \in \mathbf{R}^{n \times 1}$ 。




图 1 一维 CNN 原理图

Fig. 1 One-dimensional CNN schematic diagram

1.2 长短期时间记忆(LSTM)

普通的循环神经网络(recurrent neural network, RNN)在遇到长序列输入时会引起梯度消失与梯度爆炸,对此有研究学者提出了改进方法 LSTM^[14],它通过引入遗忘门、输入门、输出门 3 个门控开关以及记忆单元有效地解决了 RNN 中的梯度消失与爆炸问题。LSTM 单元的结构如图 2 所示。




图 2 LSTM 结构示意图

Fig. 2 LSTM structure diagram

从图 2 中可以看出,整个 LSTM 模型由输入层、多个 LSTM 记忆单元以及隐藏状态输出层组成,每一个 LSTM 记忆单元的结构相同。在图 2 中给出了 3 个 LSTM 记忆单元,其中左侧和右侧的记忆单元只给出了相应的 1/2 以表示在左侧或右侧还有多个 LSTM 记忆单元串联连接。每个记忆单元的输入分

为 3 部分,第 1 部分是来自于数据的输入即 x_t ,另两部分均为从上一个单元所传递来的细胞状态 C_{t-1} 与隐藏状态输出 h_{t-1} 。在获得 3 部分的输入之后,将会依次经过遗忘门、输入门以及输出门。其中遗忘门负责决定当前细胞状态中哪些需要遗忘或继续传递;输入门负责决定当前新输入的数据中有多少选择加入到当前的细胞状态中;输出门负责决定多少新的细胞状态可以输出。

1.3 Bayesian 算法

贝叶斯 (Bayesian) 优化算法已广泛应用于自动机器学习领域,它的主要流程如图 3 所示。




图 3 Bayesian 优化算法流程

Fig. 3 Bayesian optimization algorithm flow

从图 3 中可以看出在利用贝叶斯算法寻优之前,需要先定义需要优化选取的参数范围 θ 、代理模型 M 、采集函数 E 、需要优化的目标函数 F 以及搜寻的次数 N 。之后预先选取范围 θ 内的 K 个点进行代理模型 M 的初始化,生成最初的“先验知识”。然后根据采集函数 E 与代理模型 M 在搜寻空间 θ 中寻找下一个有可能是极值的点 x_{n+1} ,计算出该点在目标函数 F 处的取值 y_{n+1} 并更新代理模型 M ,作为寻找下一个点的新的“先验知识”,重复这一步骤,直至超过定义的搜寻次数 N ,最后即可得出最优超参数组合。

1.4 Bayesian-CNN-LSTM 混合模型

本文设计一种混合模型,结合了卷积神经网络

与循环神经网络的优势,使混合模型能具有处理时间与空间特征的能力。混合模型的结构如图 4 所示。




图 4 CNN-LSTM 结构图

Fig. 4 CNN-LSTM structure diagram

从图 4 中可以看出,输入数据先经过卷积神经网络 CNN 提取空间特征,再通过 LSTM 的堆叠对提取的特征进行学习,在学习结束后将 LSTM 层的输出作为全连接层的输入,最后得到的全连接层 (fully connected, FC) 的输出即为实际预测值。结合 Bayesian 算法的 CNN-LSTM 混合模型的预测流程如图 5 所示,其中预测的步骤如下:




图 5 Bayesian 混合 CNN-LSTM 流程图

Fig. 5 Bayesian hybrid CNN-LSTM flow chart

Step1 数据预处理。将原始运动数据进行数据标准化,将数据转化为标准正态分布,然后按照 6:2:2 的比例划分数据集为训练集、验证集与测试集,以供后续使用。

Step2 设置贝叶斯算法的参数。根据 CNN-LSTM 混合模型的优化需求进行超参数寻优,定义寻优空间以及最大寻优次数。

Step3 初始化模型结构。根据贝叶斯算法选取一组需要优化的超参数的取值,并结合固定的超参数 (输出层节点数等) 初始化 CNN-LSTM 模型的结构。

Step4 模型的训练与验证。利用 Step1 划分的训练集训练 Step3 中初始化的模型并使用验证集获

得验证误差或其他误差衡量指标。最后将当前模型与历史搜寻的超参数建立的模型对比,并保存当前最优的超参数,最后达到迭代次数,获得全局最优超参数。

Step5 最优模型预测。根据 Step4 中获取的最优超参数与其他固定的超参数初始化最优模型的结构。然后利用训练集与验证集进行模型的训练与验证,从而得到预测模型。最后将测试集的数据作为模型的输入得到相应的运动预测结果。

2 平台建模与计算

2.1 数据准备与处理

本文检验的数据取自 AQWA 软件对海工平台在不规则波中的纵荡运动数据。表 1 列出了海工平台模型的主尺度信息,图 6 显示了平台的三维建模结果。

表 1 海工平台主要参数

Tab. 1 Main parameters of offshore platform

参数	数值	参数	数值
长/m	115.0	上甲板高/m	46.0
型宽/m	75.0	下船体长/m	115.0
吃水/m	24.0	下船体宽/m	15.0
排水量/m ³	40 796.0	下船体高/m	9.0
立柱直径(大)/m	11.0	立柱直径(小)/m	9.5




图 6 海工平台三维建模

Fig. 6 Three-dimensional modeling of offshore platform

本次海工平台在 AQWA 中的设置工况见表 2。通过对设计工况下海工平台的实例分析,获得了 2 000 s 纵荡运动数据,其中数据间隔为 0.5 s。之后对标准化操作后的原始数据进行数据集划分,其中实际划分比例为(训练集:验证集:测试集=6:2:2),即选取 0~1 200 s 数据用于训练,1 200~1 600 s 数据用于验证,1 600~2 000 s 数据用于测试。

其中数据标准化的公式如下:

$$x_i^* = \frac{x_i - \bar{x}}{s} \tag{1}$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \tag{2}$$

$$s = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \tag{3}$$

式中: x_i^* 即为原始数据 x_i 标准化后的结果, $\bar{x}$ 为原始数据的均值, N 为数据集中样本点的个数, s 为原始数据的标准差。

表 2 环境载荷参数

Tab. 2 Environmental load parameters

浪向角/(°)	波浪谱	有义波高	谱峰周期	谱峰因子
180	JONSWAP	6.0	11.0	2.4

2.2 超参数寻优空间

由于混合模型输入层和输出层的节点数根据实验人为确定,故不需要对这两个超参数进行优化选取。对于 CNN-LSTM 混合模型所需要优化选取的超参数为卷积层中卷积核尺寸与个数、LSTM 中隐藏层节点个数与隐藏层数、批训练数以及全连接层节点数。超参数寻优空间见表 3。

表 3 超参数寻优空间

Tab. 3 Hyperparameter optimization space

参数	数值	参数	数值
卷积核数	range(10, 100)	隐藏层数	[1, 2, 3]
卷积核长度	range(3, 5)	隐藏层节点数	range(10, 100)
批训练数	[32, 64, 128]	全连接层节点数	range(10, 100)

注:表 3 中的 range(10, 100) 表示从 10 到 100 的所有整数。

2.3 预测效果衡量指标

衡量一个模型预测效果的优劣,一般衡量其均方误差 E_{RMS} ^[15],但由于数据大小不一,仅从均方误差的大小上衡量模型预测效果不能全面地表达模型的优劣。本文额外引入平均相对误差 E_{MR} 与效能系数 R^2 ,其中均方误差与平均相对误差越趋于 0 证明预测效果越好,效能系数 R^2 取值为 $-\infty \sim 1$, R^2 接近 1,表示模型可信度高; R^2 接近 0,表示预测结果接近观测值的平均值水平; R^2 远远小于 0,则模型是不可信的。3 个衡量指标的公式如下:

$$R^2 = 1 - \frac{\sum (X - Y)^2}{\sum x^2} \tag{4}$$

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^N (X - Y)^2}{N}} \tag{5}$$

$$E_{\text{MR}} = \frac{1}{N} \sum_{i=1}^N \frac{|X - Y|}{X} \times 100\% \tag{6}$$

$$x = X - \bar{X} \tag{7}$$

式中: R^2 为效能系数, X 即为原始数据, Y 即为预测数据, N 即为预测数据的个数, $\bar{X}$ 即为原始数据的均值, E_{RMS} 为均方误差, E_{MR} 为平均相对误差。

3 预测模型的实验

本文分别选取预测时长为 6、12、18 s。本文采

取多输入多输出的形式,从而避免因迭代误差导致的模型预测能力下降。9 种不同的预测时长与输入时长的对应关系见表 4。

表 4 不同预测 – 输入时长对应关系

预测时长/s	输入时长/s
6	18、36、54
12	18、36、54
18	18、36、54

本次实验运行的设备 CPU 为 i5-12400f,运行内存为 16 G,显卡为 NVIDIA RTX 3060,运行环境为 Python 3.8.3 和 Pytorch 1.8(cuda 12.1)。

3.1 纵荡运动 6 s 预测模型

分别使用海工平台纵荡运动前 18、36、54 s 的真实数据来预测随后 6 s 的纵荡运动。使用数据中的前 1 600 s 用于训练和衡量预测模型的预测能力,使用后 400 s 进行测试。用于测试的 400 s 运动数据的预测过程如图 7 所示。




图 7 测试集的预测过程

从图 7 中可以看出,假设当前时刻为 t_0 ,输入时长为 T ,预测时长为 t_{pre} 。模型第 1 次预测的输入为 $t_0 - T \sim t_0$,即图 7 中的 Input1,可以得到 $t_0 \sim t_0 + t_{pre}$ 相应的预测值;在下一次的预测中,模型预测的输入为上一次的输入 Input1 向右滑动 t_{pre} ,即图 7 中的 Input2 可以得到 $t_0 + t_{pre} \sim t_0 + 2t_{pre}$ 相应的预测值,直至实现完整预测。在最终的预测示意图中仅展示了 400 s 的预测时长中能整除预测时长 t_{pre} 的最大长度。

图 8 中展示了混合模型与 LSTM 模型在 6 s 预测上的对比。从图 8 中可以看出,混合模型的预测值与真实值可以做到几乎重合。通过观察预测误差的变化趋势可以看出在绝大多数区域的预测误差可以做到趋于 0,足以证明 CNN-LSTM 模型在 6 s 预测上具有良好的性能。除此之外,将 CNN-LSTM 模型与 LSTM 模型进行对比可以发现,在 50 ~ 70 s 的预测区域内(图中虚线框区域),混合模型比 LSTM 模型的预测精度更高。由于 36、54 s 的输入时长的规

律与 18 s 输入时长相同,本文只展示了 18 s 预测输入的预测效果对比。在以下不同的预测时长上同理。




图 8 6 s 预测指标对比 (输入 18 s)

Fig. 8 Comparison of 6 s prediction (Input 18 s)

由于图 8 中不能更显著地比较出 CNN-LSTM 混合模型的预测结果相较于传统 LSTM 模型的优劣,现将两种模型的对应的预测指标汇总在表 5 中。

表 5 6 s 预测指标对比

Tab. 5 Comparison of 6 s predicted indicators

模型	输入时长/s	R^2	E_{RMS}	$E_{MR}/\%$
CNN-LSTM	18	0.999 47	0.010 351 0	2.553 9
	36	0.999 51	0.010 067 0	2.561 7
	54	0.999 57	0.009 389 6	2.313 4
LSTM	18	0.999 54	0.009 626 0	2.722 4
	36	0.999 43	0.010 807 0	3.001 2
	54	0.999 47	0.010 436 0	2.939 4

从表 5 中可以看出输入时长为 18、36、54 s 时,混合模型的平均相对误差相比于单独 LSTM 模型减小了 15% 左右,CNN-LSTM 混合模型的预测性能优于单独 LSTM 模型,表现出混合模型的优越性。在 R^2 方面,所有模型的值均大于 0.99,由此表明模型的置信度较高。

3.2 纵荡运动 12 s 预测模型

分别使用海工平台纵荡运动前 18、36、54 s 的真实数据来预测随后 12 s 的纵荡运动如图 9 所示。从图 9 中可以看出,在运动峰值区域,相较于其他区域,预测效果较差,但 CNN-LSTM 模型在峰值区域(图中虚线框区域)的预测性能仍比单独 LSTM 模型的效果好。




图 9 12 s 预测指标对比 (输入 18 s)

Fig. 9 Comparison of 12 s prediction (Input 18 s)

表 6 为两种模型的 12 s 预测指标对比,从表 6 中可以看出,输入时长为 18、36、54 s 时,混合模型的平均相对误差相比于单独 LSTM 模型减小了 25% 左右,不同输入时长下混合模型的预测性能均优于单独 LSTM 模型。在 R^2 方面,所有模型的值均大于 0.99,由此表明模型的置信度高,但相较于预测时长为 6 s 时, R^2 整体有所下降,均方误差有所增大,模型的预测性能有所下降。

表 6 12 s 预测指标对比

Tab. 6 Comparison of 12 s predicted indicators				
模型	输入时长/s	R^2	E_{RMS}	$E_{\text{MR}}/\%$
CNN-LSTM	18	0.994 06	0.034 775	5.450 4
	36	0.991 89	0.040 802	6.495 1
	54	0.994 01	0.035 105	5.362 4
LSTM	18	0.991 97	0.040 432	8.006 6
	36	0.995 41	0.030 684	8.225 8
	54	0.993 15	0.037 529	7.183 6

3.3 纵荡运动 18 s 预测模型

分别使用海工平台纵荡运动前 18、36、54 s 的真实数据来预测随后 18 s 的纵荡运动如图 10 所示。从图 10 中可以看出,相较于 6 s 预测模型和 12 s 预测模型,在相同输入长度的条件下,18 s 预测模型的预测性能明显低于前两种预测模型,在峰值处容易出现忽高忽低的现象,但总体预测基本符合变化趋势并且有较高的拟合度。在图 10 中虚线框区域可以看出,混合模型的误差小于 LSTM 模型,有更好预测性能。

表 7 为两种模型在 18 s 上的预测指标对比,从表 7 中可以看出,在输入时长为 18、36、54 s 时,混合

模型的平均相对误差相比于单独 LSTM 模型减小了 30% 左右,混合模型的预测性能均优于单独 LSTM 模型。在 R^2 方面,所有模型的值均大于 0.90,由此时, R^2 整体再次下降,混合模型的平均相对误差增大至 10% 左右,相比于 6 s 预测和 12 s 预测,整体预测效果较差,但仍在误差允许范围内。表明模型的置信度较高。但相较于预测时长为 12 s 预测,整体预测效果较差,但仍在误差允许范围内。




图 10 18 s 预测对比 (输入 18 s)

Fig. 10 Comparison of 18 s prediction (Input 18 s)

表 7 18 s 预测指标对比

Tab. 7 Comparison of 18 s predicted indicators				
模型	输入时长/s	R^2	E_{RMS}	$E_{\text{MR}}/\%$
CNN-LSTM	18	0.954 38	0.096 349	9.971 0
	36	0.954 56	0.096 461	10.159 0
	54	0.958 09	0.092 817	9.792 0
LSTM	18	0.951 54	0.099 311	13.327 0
	36	0.953 84	0.097 220	13.302 0
	54	0.951 47	0.099 879	13.504 0

3.4 两种预测模型的对比分析

将不同预测时间的所有模型的衡量指标汇总见表 8。由于均方误差在对应不同的数据集时无法根据其值的大小准确反映模型的预测水平,故本文通过平均相对误差来衡量模型的预测能力如图 11 所示。

表 8 CNN-LSTM 混合模型指标汇总表

Tab. 8 Summary table of CNN-LSTM hybrid model indicators				
预测时长/s	输入时长/s	R^2	E_{RMS}	$E_{\text{MR}}/\%$
6	18	0.999 47	0.010 351 0	2.553 9
6	36	0.999 51	0.010 067 0	2.561 7

表 8(续)

预测时长/s	输入时长/s	R^2	E_{RMS}	$E_{\text{MR}}/\%$
6	54	0.999 57	0.009 389 6	2.313 4
12	18	0.994 06	0.034 775 0	5.450 4
12	36	0.991 89	0.040 802 0	6.495 1
12	54	0.994 01	0.035 105 0	5.362 4
18	18	0.954 38	0.096 349 0	9.971 0
18	36	0.954 56	0.096 461 0	10.159 0
18	54	0.958 09	0.092 817 0	9.792 0

从表 8 和图 11 中可以看出,当固定预测时长时,平均相对误差会呈现出随输入时长增加而增加的特征,这是由于当模型当前输入时长足以捕获运动数据之间的时空关系时,进一步增加输入时间长度会造成信息冗余,造成模型的“过度学习”,不利于提高模型的鲁棒性。但后续延长输入长度时,平均相对误差会出现减小的情况,这是由于延长的输入中引入了新的“模型知识”,从图 11 中可以看出模型具备较强的学习能力。




图 11 固定预测时长对比

Fig. 11 Comparison chart of fixed prediction duration

当通过固定输入时长,改变预测时长时,得到的曲线如图 12 所示,从图 12 中可以看到模型的平均相对误差近似呈线性上升趋势,即模型的预测能力越来越差,本文可以根据实际预测需求,选取满足误差要求的最大预测时长,使海上作业人员有更多的时间来对应急情况的发生。LSTM 中的规律与 CNN-LSTM 的规律相似。

除此之外,模型的训练耗时与预测耗时也是应考虑的条件,表 9 给出了在 9 个不同的输入、输出对应关系上,CNN-LSTM 模型与 LSTM 模型训练以及预测所消耗的时间,其中为了更准确的得到模型训练与预测耗时,分别进行 50 次实验并取平均,表 9 中的训练耗时指模型每训练一代的耗时,预测耗时指模型训练结束后调用测试集完整预测 400 s 的耗时。




图 12 平均相对误差与预测时长关系图

Fig. 12 Relationship between mean relative error and prediction time

表 9 预测模型训练与预测耗时

Tab. 9 Training time and prediction time of prediction models

模型名称	输入时长	6 s 预测		12 s 预测		18 s 预测	
		训练耗时	预测耗时	训练耗时	预测耗时	训练耗时	预测耗时
CNN-LSTM	18	0.325 0	0.013 00	0.235 0	0.009 14	0.118 0	0.006 00
	36	0.324 0	0.013 50	0.188 0	0.001 00	0.118 0	0.006 00
	54	0.414 0	0.013 30	0.209 0	0.011 90	0.121 0	0.007 19
LSTM	18	0.269 0	0.012 20	0.200 0	0.009 00	0.082 2	0.005 00
	36	0.279 0	0.013 20	0.169 0	0.008 01	0.088 6	0.005 26
	54	0.344 0	0.013 10	0.176 5	0.009 00	0.099 8	0.006 34

通过对比训练耗时可以得出,在 9 种不同的输入、输出时长的实验上,混合模型在每一个 epoch 的平均训练耗时约比 LSTM 模型高出 25%,其中多出的耗时是由于 CNN 的加入,额外添加了特征提取工作,使预测模型的训练参数增加。通过对比预测耗时可以发现,混合模型与 LSTM 模型在相同的预测任务上计算耗时接近,主要原因在于,在模型预测阶段不需要大量的更新权重等工作,只需利用当前模型的各个权重数据对输入进行矩阵运算等操作,而两种模型参数的数量在数量级上没有明显差异。由于训练耗时均为“秒”级别,在实际的应用过程中差异较小,因此综合预测精度与训练耗时,本文的 CNN-LSTM 模型更具有优势。

4 结 论

1)提出的 CNN-LSTM 混合模型能够预测海工平台未来一段时间的运动,在 6、12、18 s 的预测时长上平均相对误差均在 10% 以内,均具有较高的预测精度,满足应用的要求。

2)在本文研究的 3 种不同的预测时长上,证明了混合模型的预测精度均高于 LSTM 模型,在幅值区域具有更小的预测误差,总体预测精度可提高 15% ~ 30%,且随着预测时长的增加优越性越明显。

3)探究了预测精度与输入时长、预测时长之间的关系,可以看出模型的预测精度随着预测时长的增加呈现线性减小趋势,受输入时长的影响不大,可作为实际预测任务中的参考。

4)结合预测模型的训练耗时,本文的 CNN-LSTM 混合模型与 LSTM 模型的差异较小,综合预测精度与训练耗时,CNN-LSTM 模型更具有优越性。

参考文献

- [1] JIANG Yanshu, JIA Mingqi, ZHANG Biao, et al. Ship attitude prediction model based on cross-parallel algorithm optimized neural network[J]. IEEE Access, 2022, 10: 77857. DOI: 10.1109/ACCESS.2022.3193573
- [2] YAO Jianxi, LIU Zuyuan, SONG Xuemin, et al. Ship manoeuvring prediction with hydrodynamic derivatives from RANS: Development and application[J]. Ocean Engineering, 2021, 231: 109036. DOI: 10.1016/j.oceaneng.2021.109036
- [3] FU Huixuan, LIU Sheng, SUN Feng. Ship motion prediction based on AGA-LSSVM [C]//2010 IEEE International Conference on Mechatronics and Automation. Xi'an: IEEE, 2010: 202. DOI: 10.1109/ICMA.2010.5589093
- [4] CASTRO A, CARBALLO R, IGLESIAS G, et al. Performance of artificial neural networks in nearshore wave power prediction[J]. Applied Soft Computing, 2014, 23: 194. DOI: 10.1016/j.asoc.2014.06.031
- [5] YIN Jianchuan, WANG Ning, PERAKIS A N. A real-time sequential ship roll prediction scheme based on adaptive sliding data window[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 48(12): 2115. DOI: 10.1109/TSMC.2017.2735995
- [6] YAO Yuxin, HAN Liang, WANG Jiangyun. Lstm-pso: long short-term memory ship motion prediction based on particle swarm optimization [C]//2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC). Xiamen: IEEE, 2018: 1. DOI: 10.1109/GNCC42960.2018.9018688
- [7] YIN Wenpeng, SCHÜTZE H, XIANG Bing, et al. ABCNN: Attention-based convolutional neural network for modeling sentence pairs[J]. Transactions of the Association for Computational Linguistics, 2016, 4: 259. DOI: 10.1162/tacl_a_00097
- [8] WANG Wenxu, TANG Ruichun, LI Cheng, et al. A BP neural network model optimized by Mind Evolutionary Algorithm for predicting the ocean wave heights[J]. Ocean Engineering, 2018, 162: 98. DOI: 10.1016/j.oceaneng.2018.04.039
- [9] BERGSTRA J, BARDENET R, BENGIO Y, et al. Algorithms for hyper-parameter optimization [C]//Proceedings of the 24th International Conference on Neural Information Processing Systems. Granada, Spain: ACM, 2011: 2546. DOI: 10.5555/2986459.2986743
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84. DOI: 10.1145/3065386
- [11] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735. DOI: 10.1162/neco.1997.9.8.1735
- [12] LIU Yucheng, DUAN Wenyang, HUANG Limin, et al. The input vector space optimization for LSTM deep learning model in real-time prediction of ship motions[J]. Ocean Engineering, 2020, 213: 107681. DOI: 10.1016/j.oceaneng.2020.107681
- [13] 朱鹏程, 杨冰华, 荀顺达, 等. 基于 Transformer 的船舶运动预测模型研究[J]. 中国造船, 2022, 63(5): 245
ZHU Pengcheng, YANG Binghua, XUN Shunda, et al. Research on ship motion prediction model based on transformer[J]. Shipbuilding of China, 2022, 63(5): 245. DOI: 10.3969/j.issn.1000-4882.2022.05.023
- [14] HUANG Limin, DUAN Wenyang, HAN Yang, et al. Extending the scope of AR model in forecasting non-stationary ship motion by using AR-EMD technique[J]. Journal of Ship Mechanics, 2015, 19(9): 1033. DOI: 10.3969/j.issn.1007-7294.2015.09.002
- [15] JIANG Hua, DUAN Shiliang, HUANG Limin, et al. Scale effects in AR model real-time ship motion prediction [J]. Ocean Engineering, 2020, 203: 107202. DOI: 10.1016/j.oceaneng.2020.107202

(编辑 张 红)