

控制与决策

Control and Decision

基于SCI-CA模型的船舶纵摇多维多步预测方法

王宇超, 赵洵, 杨周琦, 傅荟璇

引用本文:

王宇超, 赵洵, 杨周琦, 等. 基于SCI-CA模型的船舶纵摇多维多步预测方法[J]. *控制与决策*, 2025, 40(1): 64-70.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1701>

您可能感兴趣的其他文章

Articles you may be interested in

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于最佳相位匹配的减摇鳍低航速控制策略](#)

Best phase matching based control strategy for ship stabilizer at low speed

控制与决策. 2021, 36(4): 940-946 <https://doi.org/10.13195/j.kzyjc.2019.1028>

[基于最佳相位匹配的减摇鳍低航速控制策略](#)

Best phase matching based control strategy for ship stabilizer at low speed

控制与决策. 2021, 36(4): 940-946 <https://doi.org/10.13195/j.kzyjc.2019.1028>

[一种基于深度学习的时间序列预测方法](#)

A time series prediction method based on deep learning

控制与决策. 2021, 36(3): 645-652 <https://doi.org/10.13195/j.kzyjc.2019.0809>

基于SCI-CA模型的船舶纵摇多维多步预测方法

王宇超, 赵 洵, 杨周琦, 傅荟璇[†]

(哈尔滨工程大学 智能科学与工程学院, 哈尔滨 150000)

摘要: 海洋环境复杂多变, 船舶航行容易受到风浪、洋流等因素的干扰, 船舶运动具有非线性、耦合性等特点. 针对传统的船舶运动姿态预测方法对时序数据的提取效率尚有不足, 难以达到高精度预测效果的问题, 提出样本卷积交互-通道注意力(SCI-CA)神经网络船舶纵摇运动预测模型. 该模型采用多类别船舶运动姿态数据作为输入, 将输入拆分为两个子序列, 利用样本卷积交互网络(SCI)的递归下采样卷积交互结构, 结合多分辨率聚合而成的丰富特征, 提高船舶运动数据深层特征的利用率. 再通过通道注意力机制(CA)提高有效通道的权重比例, 并以残差结构输入到全连接层, 得到最后的预测结果. 实船数据验证结果表明, SCI-CA组合模型预测结果较其他模型预测精度高, 其平均绝对百分比误差(MAPE)、均方根误差(RMSE)均有明显降低, 验证了SCI-CA模型预测船舶运动的有效性.

关键词: 船舶纵摇; SCI-Net; 通道注意力; 交互学习结构; 组合模型; 多步预测

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1701

引用格式: 王宇超, 赵洵, 杨周琦, 等. 基于SCI-CA模型的船舶纵摇多维多步预测方法[J]. 控制与决策, 2025, 40(1): 64-70.

Multi-dimensional and multi-step prediction method for ship pitching based on SCI-CA model

WANG Yu-chao, ZHAO Xun, YANG Zhou-qi, FU Hui-xuan[†]

(College of Intelligent Systems Science and Engineering, Harbin Engineering University, Harbin 150000, China)

Abstract: As the marine environment is complex and changeable, ship navigation is easily affected by factors such as wind, waves, ocean currents and other factors, and ship motion is characterized by nonlinearity and coupling. Aiming at the problem that traditional ship motion prediction methods have insufficient efficiency in extracting time series data and are difficult to achieve high-precision prediction results, a sample convolution and interaction-channel attention (SCI-CA) neural network ship pitch motion prediction model is proposed. The model uses multi-category ship motion attitude data as input, splits the input into two subsequences, utilizes the recursive down sampling convolution interaction structure of the sample convolution interaction network (SCI), and combines the rich features aggregated from multiple resolutions to improve the utilization of deep features of ship motion data. Then, channel attention mechanism (CA) is used to improve the weight ratio of effective channels, and the residual structure is input to the full connection layer to obtain the final prediction result. The simulation results of real ship data show that the prediction accuracy of the SCI-CA combined model is higher than that of other models, and its mean absolute percentage error (MAPE) and root mean square error (RMSE) are significantly reduced, verifying the effectiveness of the SCI-CA model in predicting ship motion.

Keywords: ship pitch; SCI-Net; channel attention; interactive learning structure; combination model; multi-step forecast

0 引言

船舶的航行受到海浪、洋流、风速等外界因素干扰, 产生六自由度运动. 在六自由度中, 纵摇影响船舶主机功率, 严重可致使船舶失速, 存在航行安全隐

患. 为解决纵摇带来的安全问题, 利用已有的船舶运动姿态数据, 高效精准地预测下一时段的船舶运动情况显得尤为重要. 通过对历史数据中包含的特征进行提取和分析, 预测未来时刻的数据, 可为下一阶段

收稿日期: 2023-12-08; 录用日期: 2024-04-16.

基金项目: 国家自然科学基金项目(52271313); 中央高校基本科研业务费专项资金项目(3072024GH0405).

责任编辑: 闫敬.

[†]通讯作者. E-mail: fuhuiquan@hrbeu.edu.cn.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载浏览.

的航行提供控制依据. 船舶运动姿态数据属于时间序列数据, 而现有的时间序列预测方法主要包括统计预测方法、机器学习预测方法、神经网络预测方法.

统计预测方法包括差分整合移动平均自回归模型 (autoregressive integrated moving average model, ARIMA)、回归分析 (regression analysis) 等. 传统统计预测方法常与现代控制方法和信息处理算法相结合使用, 如卡尔曼滤波 (Kalman filtering) 算法、小波 (wavelet) 算法等. 统计预测方法适用于数据集充足的条件下, 通常使用曲线拟合的方式来表示输入输出数据间的映射关系. 针对船舶升沉运动中的时延现象, 唐刚等^[1]建立了 Newton-ARMA 模型, 解决了波浪补偿系统中时延导致的控制性能下降问题. Abebe 等^[2]采用 ARIMA 方法处理线性数据, 并与 LSTM (long short term memory network) 模型组合用来预测船舶轨迹. Vanem 等^[3]采用季节性 ARIMA 与多元线性回归方法预测显著波高等海况的可靠返回期.

除统计预测方法外, 机器学习算法在时序预测中也扮演重要角色. 常用的时序预测机器学习算法有: 支持向量机算法 (support vector machines, SVM)、人工神经网络 (artificial neural network, ANN)、随机森林算法 (random forest, RF) 等. Zheng 等^[4]提出了一种基于 SVM 的船舶碰撞风险评估方法, 改进了传统二维风险评估方法未考虑船舶状态变化的问题. Campos 等^[5]开发了随机森林 (RF) 后处理模型, 并用来确定最佳波浪预报.

人工神经网络方法具有强大的计算能力, 适用于拟合非线性复杂模型. 李占英^[6]等提出了基于单项模型可筛选的船舶横摇运动组合预测方法, 对比了 BP (back propagation)、RBF (radial basis function)、DRNN 等组合网络与单向网络的预测效果. Dong 等^[7]提出一种基于 BP 和 LSTM 神经网络的组合模型, 解决了船舶运动中补偿系统的滞后问题. 刘威等^[8]将 ICCOA 算法应用于 BP 神经网络参数优化问题中, 改善了原模型性能. Luo 等^[9]提出了双向长短期记忆网络-注意力模型 (Bi-LSTM with attention, BLA) 来预测大西洋飓风区的波高问题. 在 LSTM 的基础上, Shi 等^[10]进一步提出了 ConvLSTM 网络结构, 应用于未来降雨强度预测, 证明了 ConvLSTM 预测效果优于 FC-LSTM.

除了 LSTM 和卷积网络之外, 注意力机制在时序预测中也扮演着重要的角色. 鹿天柱等^[11]针对时序数据的长期依赖性, 引入了时间注意力机制, 所提出的 DAFDC-RNN 模型在大特征量数据集上的预测

效果最佳. 王建芳等^[12]提出了一种图神经网络与注意力机制相结合的方法并应用于推荐系统. Vaswani 等^[13]提出了 Transformer 模型, 改进了卷积操作的复杂结构. 王勇等^[14]将 Transformer 与 CNN 模型相结合, 用于机械臂抓取时的图像识别. 随着 CBAM、CA、SE 等轻量化注意力机制的提出^[15-16], 计算量无大幅提高的前提下, 提升了初始网络原有的预测效果.

现有的深度学习方法在多变量船舶运动预测中取得了诸多良好的预测效果, 但也存在许多不足. 例如: 时间序列数据提取的分辨率单一, 特征间的交互较少, 预测精度仍有提升可能. 针对以上问题, 本文提出一种基于样本卷积交互-通道注意力 (sample convolution and interaction-channel attention, SCI-CA) 组合神经网络的船舶纵摇预测模型. 此模型属于时间卷积网络, 具有时间卷积网络捕捉数据长期依赖性、平移不变性的优势. 此网络可以在 GPU 上并行计算, 训练速度更快. 实验结果表明, 与对比实验模型相比, 本文提出的 SCI-CA 模型预测精度最高, 误差评价指标均有明显降低.

1 SCI-Net 和 channel attention 算法

1.1 样本卷积交互网络

SCI-Net 是基于时间卷积网络 (temporal convolutional network, TCN) 的思想构造^[17], 使用膨胀卷积的 TCN 架构具有两个缺陷, 每个层使用权值共享操作, 卷积核倾向于从前一层的数据中提取平均时间特征. 但复杂的时间序列包含大量的时间动态; TCN 模型只有最终层对全局视图进行回望操作, 中间层感受野有限, 而感受野的狭小会导致提取特征的时间关系受损. 针对这两点缺陷, 使用卷积滤波器来提取异质但重要的信息, 从多种分辨率收集动态时间相关性, 对时序数据的精准预测显得尤为重要.

SCI-Net 由 SCI-Block 作为基本单元构成, 每个 SCI-Block 又由卷积层、池化层等模块组成. SCI-Net 通过指数映射和卷积操作, 用交互学习的方式增大了中间层的感受野. SCI-Net 应用的网络结构如图 1(a) 所示. SCI-Net 采用二叉树结构, 第 l 层具有 2^{l-1} 个 SCI-Block, 共有 2^l 个基本模块. 在 SCI-Net 中, 输入序列、特征向量 $\hat{X}^{k-1} = \{\hat{x}_1^{k-1}, \dots, \hat{x}_T^{k-1}\}$ 被 SCI-Block 通过多级逐步下采样处理, 此过程实现了多种时间分辨率的隐层特征提取. 在输入数据经过了 l 层 SCI-Block 处理后, 通过残差结构, 将隐层和深层次特征添加到原始时间序列中使用全连接层进行解码操作, 输出 $\hat{X}^k = \{\hat{x}_1^k, \dots, \hat{x}_T^k\}$.

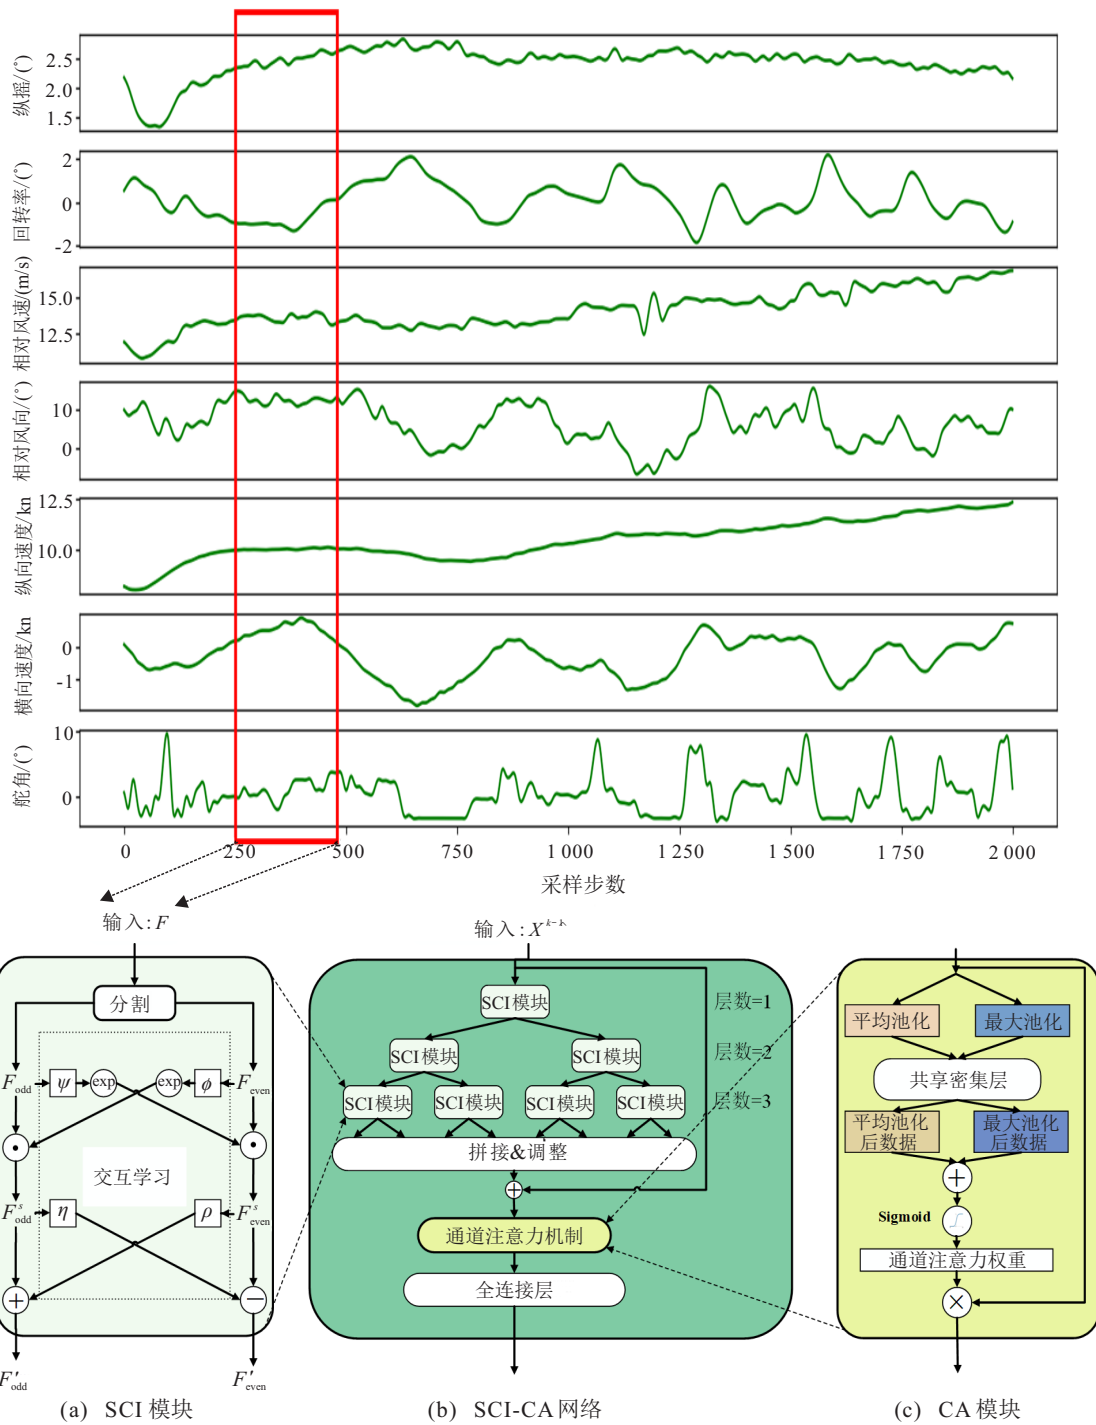


图1 样本卷积交互-通道注意力网络(SCI-CA-Net)船舶纵摇预测结构

1.2 通道注意力机制

通道注意机制是近年来提出的轻量化神经网络,其本质思想是:提高较为重要的通道权重分配的大小.对于时序数据而言,输入的特征数可理解为通道.通常采用池化手段来实现压缩,使用最大池化层和平均池化层对输入特征进行下采样操作,输入到共享参数的全连接层,对全局空间信息进行压缩,将尺寸空间的维度降低至 1×1 维,利用sigmoid函数得到 $1 \times 1 \times C$ 的权重, C 为时序数据通道的个数.通道注意力机制如图1(c)所示.

2 SCI-CA船舶纵摇预测模型

为了准确预测船舶纵摇运动,提高船舶航行的安全性,本文提出了样本卷积交互-通道注意力网络(SCI-CA-Net)的船舶纵摇预测模型,利用交互式学习提取船舶纵摇数据中深层次关联的时间信息,样本卷积对冗余信息进行筛选和删除,通道注意力机制对纵摇数据中高效部分进行二次权重赋值,提高整体纵摇数据中有效信息的占比.样本卷积交互-通道注意力网络的具体结构如图1所示.

图1所示的样本卷积交互-通道注意力网络首先

将未经处理的多输入时序数据分割成24步长的监督型学习数据,通过图1(a)部分,样本卷积交互模块将多输入时序数据拆分为奇偶两个子序列,利用3层隐含层的一维卷积对多输入奇偶子序列进行特征提取、简化和非线性处理等操作。第1层卷积核大小设置为5,第2层卷积核大小设置为3。卷积核大小不同的目的是避免原始数据经过卷积操作后通道个数发生改变。将卷积处理后的数据映射为指数形式,指数形式数据与另一半的原始数据逐元素相乘,再利用交互式学习扩大子序列的感受野,使每个子序列都具有全局的时间信息。如图1(b)部分所示,将3层SCI-Block以二叉树结构排列,堆叠形成的SCI-Net具有良好的时间信息分辨细粒度。通过反转奇偶序列拆分操作重新对多个子序列的元素进行排列,并连接成具有原始数据时间信息的新序列。对得到的新序列使用残差结构优化,保证神经网络在更深的网络层次条件下性能的稳定,同时增强时序的表达力。

残差结构将目标映射与输入的差异作为残差,供网络学习使用。残差结构分为两条路径传递,一条是恒等映射,另一条路径是通过多个卷积层进行学习映射。本实验将残差结构处理的新序列作为通道注意力机制的输入部分,通过平均池化和最大池化两种池化方式提取每个通道的特征。将通过连接层的平均池化部分和最大池化部分相加,得到的总和经Sigmoid函数进行非线性激活,生成每个通道的权重,再将输入特征和通道权重相乘,获得新的数据。通过对多个通道的数据进行提取获得不同通道的重要程度。将CA模块处理后的数据经全连接层进行输出,全连接层公式为 $\hat{X}^k = \varphi(W_{fc}x^{k-1}) + b$ 。其中: φ 是卷积操作, W_{fc} 是权重矩阵, x^{k-1} 是输入数据, b 是偏置单元。用步长为1的卷积组成全连接层,全连接层的输出维度设置为预测的步长数,得到3个步长的预测值数据,即未来3步的纵摇预测值。

3 船舶纵摇预测实验结果分析

3.1 监督学习数据选取

本实验使用的模型为基于深度学习的神经网络,所用的数据集为3级海况下实船采集的数据,实船航速为25节。本实验将纵摇、回转率、相对风速、相对风向、纵向速度、横向速度和舵角的历史数据作为输入,预测船舶未来的纵摇角。输入的7个特征前24步长的数据作为历史训练数据,同时输出未来3个时刻的预测纵摇值。

3.2 数据预处理和实验环境

数据集的样本数为32371,采样步数为0.2s,采用数据集前70%的数据作为训练集,20%的数据作为

验证集,后10%的数据作为测试集。

由于原始数据的波动变化较大,选取Z-score标准化方法,将原始数据处理成符合标准正态分布的数据。标准化公式如下所示:

$$x^* = \frac{x - \mu}{\sigma}, \quad (1)$$

其中 μ 和 σ 分别是所有样本数据的均值和标准差。

3.3 模型预测性能指标

评价一个模型的预测性能,通常使用如下4种误差指标:

1) 均方误差(MSE)

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2; \quad (2)$$

2) 平均绝对误差(MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|; \quad (3)$$

3) 平均绝对百分比误差(MAPE)

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|; \quad (4)$$

4) 均方根误差(RMSE)

$$RMSE = \sqrt{\sum_{i=1}^n (\hat{y}_i - y_i)^2 / n}. \quad (5)$$

均方误差(MSE)表示实际值与预测值之差平方的期望值。平均绝对误差(MAE)可以用来衡量预测模型的精确度,MAE的值越小,说明预测模型精度越高。平均绝对百分比误差(MAPE)用来衡量不同模型对同一组数据的效果。RMSE反映真实值和预测值的误差。

为了有效说明本模型较其他模型有更好的预测精度,选取5个时序预测常用的模型与提出的SCI-CA模型进行对比。对比实验模型包括:随机森林回归(RFR)、LSTM、GRU(gate recurrent unit)、Informer、SCI。采用提升均方误差(PMSE)、提升平均绝对误差(PMAE)、提升平均绝对百分比误差(PMAPE)、提升均方根误差(PRMSE)作为本实验的评价指标,即

$$PMSE = \frac{MSE_1 - MSE_2}{MSE_1}, \quad (6)$$

$$PMAE = \frac{MAE_1 - MAE_2}{MAE_1}, \quad (7)$$

$$PMAPE = \frac{MAPE_1 - MAPE_2}{MAPE_1}, \quad (8)$$

$$PRMSE = \frac{RMSE_1 - RMSE_2}{RMSE_1}. \quad (9)$$

3.4 模型参数设置

SCI-CA参数众多,为了得到最优的训练模型,使用交叉变量验证方法来优化模型的训练参数。对于

船舶纵摇预测模型的主要超参数如表1所示。

表1 SCI-CA 参数表

参数	参数设置
预测步长	3
输入步长	24
一组训练数	192
学习率	0.003
隐层个数	3.0
卷积核大小	5
丢弃率	0.2
堆叠层数	3

3.5 船舶纵摇预测实验结果及分析

本实验每批次选取192组数据,输入数据的维度为 $192 \times 7 \times 24$ 。为减少异常值对于实验结果的影响,选取 L 损失函数作为损失函数,有

$$L = \frac{1}{\tau} \sum_{i=0}^{\tau} |y_i - \hat{y}_i|. \quad (10)$$

其中: τ 是样本总数, y_i 是真实值, \hat{y}_i 是模型的预测值。

本文的学习率调整策略和训练机制采用了自适应动量估计(adaptive moment estimation, Adam)方法和早停机制。图2显示了SCI-CA模型在500个采样步数内的真实值和第1步预测值对比情况。图2中,黑色曲线代表真实纵摇数据,红色曲线代表SCI-CA模型预测的纵摇值。在0~100采样步数内纵摇波动较小的情况下,SCI-CA模型的预测值几乎与真实值重叠。而在101~220采样步数内纵摇值波动后上升的情况下,SCI-CA模型仍然可以较好地跟踪真实值的波动情况。即使在221~290区间大幅度提升的极值附近,SCI-CA预测值仍然稳定跟随真实值。可以看出实际误差微小,几乎可以完全拟合极值条件下的真实值。而对于291~380区间内短时间骤降的纵摇真实值,SCI-CA模型拟合精确。在381~500近似周期波动条件的采样区间内,SCI-CA模型预测稳定,呈现出




图2 SCI-CA模型的纵摇预测结果

类周期的波动情况,与真实值运动情况相同。

图3展示了各模型多步预测第1步的预测结果。图3中,0~100采样步数内纵摇波动较小,各种模型预测效果较好。101~220区间内纵摇值产生了波动,可以看出采用神经网络学习方法的模型预测效果较好,能较为准确地表达波动趋势,但精度不及SCI-CA模型。221~290区间内纵摇大幅度提升,随机森林方法和Informer预测极值的能力不足,在极值附近的误差较大;而在两个局部极值相邻且变化较小的极限条件下,LSTM和GRU的预测不及SCI精准,变化的趋势较大;SCI-CA模型在SCI模型预测的基础上提高了精度,更加逼近真实值曲线,预测效果优于其他对比实验。在291~380区间内纵摇值急速下降的条件下,统计学习方法的RFR模型误差很大,预测情况不理想;Informer虽然可以较好地表达数据变化趋势,但受之前极值点预测误差影响,无法完全贴合纵摇真实值下降的情况,不能很好地满足精度要求;LSTM、GRU、SCI-Net、SCI-CA模型在短时间下降条件下的拟合效果均较好,但SCI-CA模型具有更好的精度优势。在381~500区间类似周期信号波动的情况下,SCI-CA模型可以贴合真实数据的每个波峰和波谷值,且预测精度较高。




图3 船舶纵摇对比实验(第1步)

图4和图5展示了多步情况下各模型预测效果对比。可以看出第2步和第3步的预测情况不如第1




图4 船舶纵摇对比实验(第2步)




图5 船舶纵摇对比实验(第3步)

步准确,各个模型都体现出误差有所增加.与其他模型相比,SCI-CA模型的多步预测水平稳定,呈现的预测变化浮动不大且与真实值较为接近,多步预测效果较好.

图6展示了各模型的预测误差,对比了多模型在多步预测中得到的误差值,预测误差公式为 $e_i = \hat{y}_i -$

y_i . 其中: \hat{y}_i 是第*i*个采样时刻的预测值, y_i 是对应的真实值.从上到下,分别是第1步到第3步的预测误差对比.可以看出,SCI和SCI-CA模型的预测精度较高.虽然SCI模型的误差值下限略微小于SCI-CA模型,但SCI-CA的最大误差值远远小于SCI模型.总体上SCI-CA模型预测精度最高,预测效果最好.相比于其他模型,SCI-CA模型的预测误差值幅度最小,且波动变化较SCI-Net平缓,在极值条件下误差也较小.各模型在第2步和第3步预测误差均有不同幅度的上升.其中,SCI-CA模型的上升幅度仍然较小,在极值点变化趋势较稳定,没有产生如LSTM和Informer模型的极值突变情况.综合多步预测判断,SCI-CA对极限数据不敏感,拥有最好的预测精度和较高的抗干扰性.




图6 多模型多步误差

表2为本实验模型在船舶运动数据集上的预测误差.表2中每个指标的最小值和最大值加粗表示.SCI-CA模型的正态分布、MAE、MAPE、RMSE分别为 0.368×10^{-3} , 0.0128, 8.40%和0.0192,均为上述模型评测指标的最低值.其中RFR模型的MAPE最高,为13.67%,表明预测值较真实值误差百分比比较大,预测精度不如其他模型.Informer的MSE、RMSE与MAE较大,分别为0.01602、0.1265和0.0982.综合所有模型,拥有多时间分辨率和交互学习方式的SCI预测效果较好.而本文提出的SCI-CA模型进一步提高了原始网络的性能,实现了更高的预测精度,预测效果最好.为了进一步说明模型的预测效果,表3列出了其他5个模型相对于SCI-CA预测的PMSE、PMAE、

PMape、PRMSE.

表2 各个模型的预测性能指标

模型	MSE/ 10^{-3}	MAE	MAPE	RMSE
LSTM	2.274	0.0316	12.575	0.0476
GRU	1.374	0.0264	9.4313	0.0370
RFR	6.760	0.0619	13.668	0.0822
Informer	16.02	0.0982	9.8209	0.1265
SCI	0.540	0.0157	9.1982	0.0232
SCI-CA	0.368	0.0128	8.3988	0.0192

如表3所示,与Informer模型相比,SCI-CA模型的正态分布指数下降了97.70%,MAE下降了86.96%,RMSE指数下降了84.82%;与RFR模型相比,SCI-CA模型的正态分布指数下降了38.55%.SCI-CA的鲁棒性较强,预测结果比其他模型更精确.

表3 SCI-CA与其他模型的提升百分比 %

模型	PMSE	PMAE	PMAPE	PRMSE
LSTM	83.81	59.49	33.21	59.66
GRU	73.22	51.52	10.95	48.11
RFR	94.56	79.32	38.55	76.64
Informer	97.70	86.96	14.48	84.82
SCI	31.85	18.47	8.691	17.24

4 结论

本文针对船舶纵摇运动数据的非线性和时变性问题,提出了将SCI-CA模型用于船舶纵摇预测. SCI-CA模型使用不同分辨率的卷积操作,通过拆分原始序列获得子序列,最大程度地利用原始时序数据中的深层信息.同时,采用交互学习,扩大了卷积的感受野.采用通道注意力机制,对较为重要的特征通道赋予更大的权重,实现了多变量输入预测单变量数据的多步预测.就真实船舶纵摇运动数据的结果而言,均方误差降至 3.68×10^{-4} ,平均绝对误差降至0.0128,有效验证了所提出模型对于船舶纵摇运动具有较高的预测精度,能够为船舶航行控制安全提供保障.

参考文献(References)

- [1] 唐刚,姚小强,胡雄.基于Newton法优化ARMA模型参数的船舶升沉运动预测研究[J].海洋工程,2020,38(2):27-38.
(Tang G, Yao X Q, Hu X. Research on prediction of vessel's heave motion based on Newton method for optimizing ARMA model parameters[J]. The Ocean Engineering, 2020, 38(2): 27-38.)
- [2] Abebe M, Noh Y, Kang Y J, et al. Ship trajectory planning for collision avoidance using hybrid ARIMA-LSTM models[J]. Ocean Engineering, 2022, 256: 111527.
- [3] Vanem E, Walker S E. Identifying trends in the ocean wave climate by time series analyses of significant wave height data[J]. Ocean Engineering, 2013, 61: 148-160.
- [4] Zheng K, Chen Y B, Jiang Y, et al. A SVM based ship collision risk assessment algorithm[J]. Ocean Engineering, 2020, 202: 107062.
- [5] Campos R M, Costa M O, Almeida F, et al. Operational wave forecast selection in the Atlantic Ocean using random forests[J]. Journal of Marine Science and Engineering, 2021, 9(3): 298.
- [6] 李占英,徐亮,初红霞,等.单项模型可筛选的船舶横摇组合预测[J].控制与决策,2014,29(7):1306-1310.
(Li Z Y, Xu L, Chu H X, et al. Ship roll combination prediction based on single model screening[J]. Control and Decision, 2014, 29(7): 1306-1310.)
- [7] Dong G N, Xu Y Y, Li G J, et al. Prediction of vessel's heave motion based on combined optimization of BP network and LSTM network[J]. Ship Engineering, 2022, 44(3): 55-60.
- [8] 刘威,付杰,周定宁,等.基于反时限混沌郊狼优化算法的BP神经网络参数优化[J].控制与决策,2021,36(10):2339-2349.
(Liu W, Fu J, Zhou D N, et al. Parameter optimization of BP neural network based on coyote optimization algorithm with inverse time chaotic[J]. Control and Decision, 2021, 36(10): 2339-2349.)
- [9] Luo Q R, Xu H, Bai L H. Prediction of significant wave height in hurricane area of the atlantic ocean using the Bi-LSTM with attention model[J]. Ocean Engineering, 2022, 266: 112747.
- [10] Shi X, Chen Z, Wang H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[C]. Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 1. Cambridge: MIT Press, 2015: 802-810.
- [11] 鹿天柱,钱晓超,何舒,等.一种基于深度学习的时间序列预测方法[J].控制与决策,2021,36(3):645-652.
(Lu T Z, Qian X C, He S, et al. A time series prediction method based on deep learning[J]. Control and Decision, 2021, 36(3): 645-652.)
- [12] 王建芳,文茜琳,杨许,等.基于偏差的图注意力神经网络推荐算法[J].控制与决策,2022,37(7):1705-1712.
(Wang J F, Wen X L, Yang X, et al. A bias-based graph attention neural network recommender algorithm[J]. Control and Decision, 2022, 37(7): 1705-1712.)
- [13] Vaswani A, Shazeer N M, Parmar N, et al. Attention is all you need[J/OL]. 2018, arXiv: 1706.03762.
- [14] 王勇,李邑灵,苗夺谦,等.基于Transformer-CNN混合架构的跨模态融合抓取检测[J].控制与决策,DOI:10.13195/j.kzyjc.2023.1152.
(Wang Y, Li Y L, Miao D Q, et al. Cross-modal fusion grabbing detection based on transformer-CNN hybrid architecture [J]. Control and Decision, DOI: 10.13195/j.kzyjc.2023.1152.)
- [15] Woo S, Park J, Lee J Y, et al. CBAM: Convolutional Block attention module[J/OL]. 2018, arXiv: 1807.06521.
- [16] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, 2021: 13713-13722.
- [17] Liu M H, Zeng A L, Chen M X, et al. SCINet: Time series modeling and forecasting with sample convolution and interaction[J/OL]. 2021, arXiv: 2106.09305.

作者简介

王宇超(1979—),男,副教授,博士,博士生导师,主要研究方向为人工智能及深度学习、船舶运动控制, E-mail: wangyuchao@hrbeu.edu.cn;

赵洵(2000—),男,硕士生,主要研究方向为深度学习、智能预报, E-mail: zhaoxun61@hrbeu.edu.cn;

杨周琦(2000—),女,硕士生,主要研究方向为深度学习、智能预报, E-mail: yangzhouqi@hrbeu.edu.cn;

傅荟璇(1981—),女,副教授,博士,硕士生导师,主要研究方向为模式识别、智能控制, E-mail: fuhuiquan@hrbeu.edu.cn.