

基于 VMD-LSTM-Attention 模型的船舶 横摇运动极短期预报

孟浩然, 袁 梦, 耿 涛, 姚汉文, 郭孝先*
(上海交通大学 船舶海洋与建筑工程学院, 上海 200240)

摘 要: [目的]为了提高船舶横摇运动的极短期预报性能, [方法]将变分模态分解算法与加入注意力机制的长短期记忆神经网络相结合, 搭建具有时序特征挖掘能力的网络结构, 用于远洋航行中船舶的横摇运动预报。以安装在远洋船舶上的横摇监测系统获取的船舶横摇运动时历为测试算例, 验证该模型的有效性。[结果]研究表明: 在提前预报时长达到 12 s 时, 横摇预报结果的平均绝对误差 (MAE) 为 0.89° 、均方根误差 (RMSE) 为 1.13° , 变分模态分解-长短期记忆网络-注意力机制组合模型 (VMD-LSTM-Attention) 的预报精度相较于长短期记忆网络模型 (LSTM) 和变分模态分解-长短期记忆网络模型 (VMD-LSTM) 至少提高 15.3%。低海况下预报准确率可以达到 95% 以上, 中高海况下预报准确率达到 90%, 模型具有良好的泛化性。[结论]研究结果可为船舶在远洋航行中的横摇运动预报提供参考。

关键词: 船舶横摇运动; 长短期记忆网络 (LSTM); 变分模态分解 (VMD); 注意力机制
中图分类号: U675.5 **文献标志码:** A **【DOI】** 10.13788/j.cnki.cbge.2026.05.05

Ultra-Short-Term Prediction of Ship Roll Motion Based on VMD-LSTM-Attention Model

MENG Haoran, YUAN Meng, GENG Tao, YAO Hanwen, GUO Xiaoxian*
(School of Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: [Purpose] To enhance the ultra-short-term prediction performance of ship roll motion, [Method] the variational mode decomposition (VMD) algorithm is combined with a long short-term memory (LSTM) neural network incorporating an attention mechanism, constructing a network structure capable of mining temporal features for the prediction of ship roll motion during ocean voyages. The proposed model is validated using real-time roll motion data obtained from a monitoring system installed on an oceangoing vessel. [Result] The results show that for a prediction horizon of 12 s, the model achieves a mean absolute error (MAE) of 0.89° and a root mean square error (RMSE) of 1.13° . Compared to the standalone LSTM model and the VMD-LSTM model, the VMD-LSTM-Attention model improves prediction accuracy by at least 15.3%. Under low sea states, the prediction accuracy exceeds 95%, while under moderate to high sea states, it reaches 90%, indicating strong generalization capability. [Conclusion] The research results can provide a reference for the roll motion prediction of ships during ocean voyages.

Key words: ship roll motion; long short-term memory network (LSTM); variational mode decomposition (VMD); attention mechanism

收稿日期: 2025-08-28; 修回日期: 2025-10-31

作者简介: 孟浩然 (2001—), 男, 硕士研究生。研究方向: 船舶运动预报。

通信作者: 郭孝先 (1991—), 男, 博士、副研究员。研究方向: 事海洋结构物运动响应与载荷。

E-mail: xiaoxguo@sjtu.edu.cn。

0 引言

船舶在海上航行时会产生横摇、纵摇等6个自由度的运动, 持续扰动船上设备, 降低海上作业的安全性和工作效率^[1]。船舶运动预报基于历史时历数据预报未来运动状态, 能够有效降低海洋航运与作业风险。通过提前给出船载稳定平台的运动趋势, 实时调整平台的姿态, 能够使搭载设备始终保持稳定。因此, 开展船舶运动预报相关研究具有重要的工程应用价值与现实意义。

根据预报原理差异, 现有主流船舶运动预报方案可划分为2类: 1) 基于水动力学控制方程的机理建模与数值模拟方法; 2) 依靠历史时序数据驱动的外推预测方法。最初, TRIANTAFYLLOU等^[2-3]将卡尔曼滤波技术应用于波浪中航行的驱逐舰的极短期运动预测, 实现了5 s时间尺度的运动预测。该类方法基于水动力学理论建立舰船运动物理模型, 模型结构较为复杂, 且预测精度在很大程度上依赖物理模型的准确性。PENG等^[4]提出了一种无迹卡尔曼滤波器 (Multivariate Unscented Kalman Filter, MUKF) 算法, 旨在抑制异常数据干扰, 提升动力定位船舶状态估计的鲁棒性。TAKAMI等^[5]引入实测自相关函数 (Auto-Correlation Function, ACF), 实现了船舶运动的实时确定性预报。相比之下, 基于物理模型的预报方法往往结构复杂、计算效率较低, 在处理不规则波浪激励下具有强非线性、非平稳特征的船舶运动序列时, 预测性能仍存在明显不足^[6]。

时序外推预报方法通过对船舶运动历史序列进行建模, 捕捉时序变化特征以实现预测, 具有良好的实时性和自适应性^[7]。此类方法主要分为传统机器学习模型和神经网络模型两大类。XU等^[8]提出一种基于滑动时间窗口与最小二乘支持向量机 (Least Squares Support Vector Machine, LS-SVM) 相结合的预测方法, 通过窗口内样本完成模型训练, 并采用自动移动网格搜索 (Automatic Grid Search, AGS) 策略实现超参数在线优化。研究结果显示, 该方法能够有效实现船舶在波浪中横摇运动的实时预测。在传统机器学习方面, 陈东洋^[9]构建了增量集成随机森林回归预测模型 (Incremental Ensemble Random Forest Regression, IERFR)。该模型以回归树为基础学习器, 结合样本丢弃策略对数据集进行高效处理, 在控制模型规模与复杂度的同时降低内存占用。在Wigley-III、KCS和C60这三类船型数据集上的验证结果表明, IERFR模型可在静水条件下准确预测船舶性能, 为船型优化设计提供可靠依据。神经网络作为一类优秀的时间序列预测工具, 能够有效学习数据中复杂的非线性映射关系。在处理多变量交互、动态耦合的时间序列预测问题时, 该方法无需依赖显式物理先验, 即能够灵活地处理多尺

度、多趋势混杂的数据, 展现出较强的泛化能力和适应性。刘煜城^[10]基于TensorFlow及Keras框架, 验证了长短期记忆 (Long Short-Term Memory, LSTM) 神经网络模型在船舶运动预测中的有效性, 并对建模过程中的关键策略进行深入剖析, 形成了一套完整的神经网络建模流程。该研究重点关注输入向量定阶问题, 创造性地设计了基于自相关函数的定阶方案。SILVA等^[11]采用5415船模在长峰不规则波中的试验数据, 建立基于LSTM网络的船舶运动预测模型, 实现了对波浪环境下船舶运动响应的准确预估。李昊波等^[12]应用长短期记忆神经网络, 提出了一种面向浮式海洋平台运动响应的极短期在线预报策略, 并在多类工况条件下完成了预报验证与结果分析。研究表明, 该在线预报方法在12 s预报时长内效果良好, 纵荡、垂荡和纵摇运动的预测准确率分别达到90%、93%和85%以上。

单个模型往往受其固有结构的约束, 易出现梯度消失、易陷入局部最优、泛化与迁移能力有限等问题。因此, 在解决海上结构运动的预测问题时, 研究人员通常会集中精力开发混合模型, 以获得更好的性能。GUO等^[13]引入高斯过程回归来优化深度学习模型, 提高了对海洋平台垂荡运动的预报精度。在训练过程中对数据施加噪声, 有助于增强模型提取泛化特征的能力, 使其在含不同噪声水平的测试集上表现出更强的鲁棒性。马永艳等^[6]基于变分模态分解 (Variational Mode Decomposition, VMD) 和神经网络模型, 将时序卷积神经网络 (Temporal Convolutional Network, TCN) 和LSTM相结合, 提出一种融合北方苍鹰优化算法 (Northern Goshawk Optimization, NGO) 的VMD-TCN-LSTM混合模型。在预报提前量为5 s和10 s时, 该模型能准确预测船舶纵摇和垂荡运动。PENG等^[14]将LSTM神经网络、粒子群优化 (Particle Swarm Optimization, PSO) 与经验模态分解 (Empirical Mode Decomposition, EDM) 相结合, 构建了用于船舶垂荡运动预报的混合模型, 实际应用结果表明该模型性能达到预期目标。张睿等^[15]提出将传统LSTM模型和改进的LSTM-OneShot模型进行预训练, 借用梯度提升决策树 (GBDT) 算法和集成学习思路, 基于Transformer模型引入注意力机制来修正预报残差。该方法可以显著提高预报精度。WANG等^[16]提出基于时间序列的时间模式注意力机制 (Temporal Pattern Attention, TPA), 通过对同一时刻不同变量进行自适应加权, 突出关键变量的贡献; 并将该TPA机制与双向长短期记忆网络 (Bidirectional Long Short-Term Memory, BLSTM) 融合, 构建出预报性能显著提升的新型预测模型。此外, 现有相关研究大多采用船舶仿真运动数据或船模试验数据为训练数据集, 少数研究使

用真实船舶实测数据。

为提高船舶横摇运动的预测精度，解决其时间序列数据中存在的长期依赖关系及噪声干扰问题，本文构建了一种融合VMD、LSTM与注意力机制的组合预报模型。该模型在继承LSTM长时记忆优势的基础上，结合VMD对时序信号的深层特征分解能力以及注意力机制对关键信息的自适应筛选能力，能够有效提升预报的准确性与鲁棒性。为验证本文主要方法的有效性，以远洋船舶真实横摇运动时历数据为输入，进行多种模型训练研究，实现对真实船舶横摇运动的准确预报。

1 预报模型与方法

1.1 长短期记忆网络

在深度学习网络中，循环神经网络是处理时序预测问题的典型模型，在非线性历史时序数据预报领域具有显著优势。训练循环神经网络时，须沿时间轴将其展开为具有参数共享特性的多层前馈架构，输入序列的时间步长直接决定网络展开深度。当该记忆深度过大时，不仅会降低模型训练效率，还易引发梯度消失或梯度爆炸等问题。无论是梯度消失还是梯度爆炸，都会阻碍循环神经网络中浅层权重的有效更新，从而削弱模型对长时间跨度输入信息的记忆能力。因此，传统循环神经网络（Recurrent Neural Network, RNN）在处理长序列任务时普遍存在长期依赖建模不足的问题。

为克服上述局限，LSTM在RNN基础上引入门控机制，包括输入门、遗忘门和输出门。这些门控单元通过相互协作，在信息传递过程中引入可控时滞，并在记忆单元中维持误差的稳定传播，从而有效抑制梯度的异常变化。该机制不仅避免了梯度消失与梯度爆炸，也显著增强了模型对长时序依赖关系的捕捉能力。

1.2 注意力机制

注意力机制通过模拟人类在处理信息时对关键内容的聚焦行为，实现对关键信息的增强与噪声抑制。其核心是根据查询（Q）和键（K）之间的相关性，对值（V）进行加权重构。为了充分提取数据中的深层特征，本文引入了多头注意力机制，将查询（Q）、键（K）和值（V）在时间维度上切分为8个头部进行并行计算，并将所有头部的输出结果融合拼接作为最终表征，见图1。

首先，通过注意力汇聚函数 F 计算查询（Q）矩阵与键（K）矩阵中向量之间的相关性，并利用Softmax函数对相关性分数归一化至0~1的范围内，再将归一化后的注意力权重与值（V）矩阵相乘，实现对V的重新加权分配。

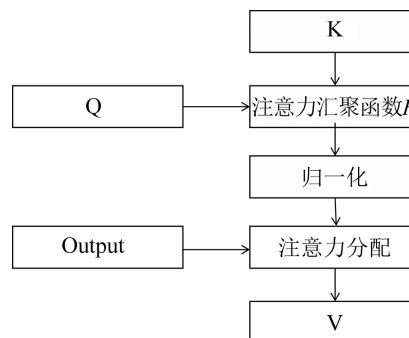


图1 注意力机制结构图

Fig. 1 Attention Mechanism Structure Diagram

具体地，该方法先生成 Q 、 K 和 V 向量：权重参数 W_q 、 W_k 和 W_v 经初始化后由神经网络训练得到；输入向量 X 、 Y 和 Z （即每个IMF分支中LSTM编码器的输出）分别通过线性变换层提取基础特征，以生成相应的 Q 、 K 和 V 向量：

$$Q = X \cdot W_q \quad (1)$$

$$K = Y \cdot W_k \quad (2)$$

$$V = Z \cdot W_v \quad (3)$$

注意力权重通过计算查询（Q）与键（K）之间的内积获得，并经由Softmax函数进行归一化处理，最终将所得权重与值（V）矩阵相乘，生成注意力输出为

$$A_{\text{attention}}(Q, K, V) = \text{Softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_k}} \right) \cdot V \quad (4)$$

1.3 变分模态分解

VMD是由DRAGOMIRETSKIY和ZOSSO于2014年提出的一种先进信号处理方法。与传统的递归时域滤波方法不同，该算法采用非递归的变分框架，通过优化迭代过程自适应地确定各模态的中心频率及带宽参数。这种基于变分原理的自适应分解机制，可有效缓解传统方法中常见的端点效应和模态混淆问题。作为一种数据驱动的分析方法，VMD可将复杂信号解耦为若干具有不同时间尺度的本征模态函数（Intrinsic Mode Functions, IMFs）。这些模态本质上属于调幅-调频信号，能够从多时间尺度角度揭示时间序列的内在变化特征。每个IMF分量对应一种特定的振荡模式或趋势项，从而实现原始信号多层次动态特征的有效提取和表征。变分问题的构造和求解过程如下。

假设原始信号能够分解为 K 个中心频率互不重叠且带宽受限的本征模态函数（IMFs），在所有模态分量之和严格等于原始信号的约束条件下，使各模态估计带宽之和最小。基于该优化目标，可构建如下约束变分模型：

$$\min_{\{u_k, \omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (5)$$

$$\text{s.t.} \quad \sum_{k=1}^K u_k(t) = f(t) \quad (6)$$

式中: K 为本征模态函数 (IMFs) 的数量; $f(t)$ 为原始信号; $u_k(t)$ 为分解得到的第 K 个模态分量; $\delta(t)$ 为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left[\lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right] \quad (7)$$

使用交替方向乘子法计算此问题的鞍点, 获得最优的模态分量及其对应中心频率。具体过程如下。

1) 初始化模态分 $\{u_k\}$ 、中心频率 $\{\omega_k\}$ 和拉格朗日乘子 λ , 并设置初始迭代次数 $n=0$, 在每一次迭代过程中, 根据更新步骤对 u_k 、 ω_k 和 λ 进行交替优化。

2) 在非负频率区间内更新 u_k 。

$$\hat{u}_{k,n+1}(\omega) = \frac{f(\omega) - \sum_{i=1}^{k-1} \hat{u}_i(\omega) + \frac{\hat{\lambda}_n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (8)$$

式中: $\hat{u}_{k,n+1}(\omega)$ 、 $\hat{\lambda}_n(\omega)$ 和 $f(\omega)$ 分别为相应函数的傅里叶变换。

3) 更新 ω_k :

$$\omega_{k,n+1} = \frac{\int_0^\infty \omega |\hat{u}_{k,n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_{k,n+1}(\omega)|^2 d\omega} \quad (9)$$

4) 更新 λ :

$$\hat{\lambda}_{n+1} = \hat{\lambda}_n + \tau \left[f(\omega) - \sum_{k=1}^K \hat{u}_{k,n+1}(\omega) \right] \quad (10)$$

5) 重复步骤2)~步骤5), 直至满足迭代停止条件。

$$\frac{\sum_{k=1}^K \left\| \hat{u}_{k,n+1} - \hat{u}_{k,n} \right\|_2^2}{\left\| \hat{u}_{k,n} \right\|_2^2} < \varepsilon \quad (11)$$

1.4 VMD-LSTM-Attention 模型结构

本文采用如图2所示的预测框架, 该系统主要由数据输入、信号分解、智能预测及结果融合四大功能模块构成。具体实施步骤如下: 1) 对原始时序数据进行规范化预处理; 2) 利用VMD算法将其解耦为多个IMFs; 3) 将各IMF分量输入至引入注意力机制的长期短期记忆网络中, 利用注意力机制自动捕获时序特征间的动态关联权重; 4) 对各分量的预测结果进行线性叠加以实现信号重构, 并完成预测精度评估与误差溯源分析。

本文采用的混合预测模型关键参数设置如下: 批量大小为64; VMD部分设定模态数 $K=5$, 以实现原始时间序列的多尺度特征提取; LSTM网络隐

单位脉冲函数; ω_k 为各模态分量的中心频率。

为了将约束优化问题转化为无约束形式, 可以引入惩罚因子 α 和拉格朗日乘子 $\lambda(t)$ 。从而构建出对应的增广拉格朗日函数, 以处理原问题中的非线性约束。

藏层维度设为128, 以增强时序特征的建模能力; 注意力机制采用8头并行计算结构, 用以捕捉不同特征子空间的依赖关系, 其中单头键/查询维度为64, 单头值维度为64, 投影层维度为512; 在注意力层后引入Dropout机制 (失活率0.01) 以抑制过拟合, 并结合早停策略动态终止训练过程, 进一步提升模型泛化性能。

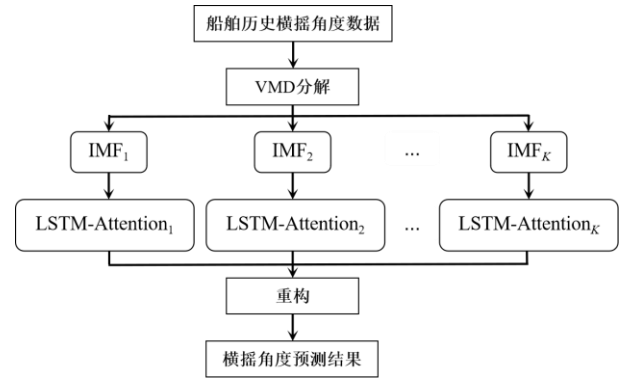


图2 VMD-LSTM-Attention 模型结构

Fig. 2 VMD-LSTM-Attention Model Structure

通过多尺度分解、高维特征学习与自适应权重分配, 上述参数配置能够有效提升模型的预测精度与鲁棒性。

2 试验和结果分析

2.1 实测数据和预处理

为了验证组合模型的有效性, 本文采用实际测量数据进行测试, 船舶运动数据集皆由安装在实船上的横摇监测系统获取。横摇监测系统架构见图3。

船舶横摇监测系统通过读取传感器数据, 经本地处理与数据存储, 最终将数据上传至云端服务器, 系统采样频率为5 Hz。本文收集整理了3艘62K纸浆船各3个月的横摇实测数据, 并利用数据集进行船舶横摇运动预报分析。3艘船的主尺度参数一致: 船长201.8 m, 船宽32.3 m, 设计吃水13.3 m, 设计载重62 000 t。

本文统计了每条船横摇时历幅值在 $0 \sim 2^\circ$ 、 $2 \sim 5^\circ$ 、 $5 \sim 10^\circ$ 及 10° 以上对应的波所占的时间, 具体

比例见表1。

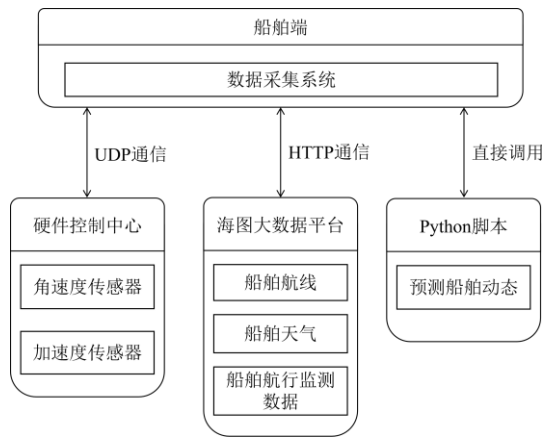


图3 横摇监测系统架构

Fig. 3 Roll Monitoring System Architecture

表1 各船有效航行时间及各幅值区间对应波累计时间占比

Tab. 1 Effective Navigation Time of Each Ship and Proportion of Cumulative Wave Time Corresponding to Each Amplitude Range

纸浆船编号	有效航行时间/d	各幅值区间对应波累计时间占比/%			
		0~2°	2~5°	5~10°	10°以上
1	56	32.8	39.6	27.5	0.1
2	49	28.2	33.8	37.6	0.4
3	70	23.9	34.1	41.7	0.3

本文统计了3艘船的吃水随航行天数的变化情况，见图4~图6。




图4 1号船吃水变化

Fig. 4 Change in Draft of Ship No. 1




图5 2号船吃水变化

Fig. 5 Change in Draft of Ship No. 2




图6 3号船吃水变化

Fig. 6 Change in Draft of Ship No. 3

本文从3组数据集中各选取了1艘船舶航线轨迹，见图7~图9。以及每条轨迹对应的船舶2 000 s的横摇运动时历，




图7 1号船横摇运动

Fig. 7 Rolling Motion of Ship No. 1




图8 2号船横摇运动

Fig. 8 Rolling Motion of Ship No. 2




图9 3号船横摇运动

Fig. 9 Rolling Motion of Ship No. 3

本文选取1号船和2号船的横摇时历作为训练集, 3号船的横摇时历作为测试集; 每艘船上各采集 54 000组原始监测数据以构建数据集, 用以检验模型在真实船舶运动预报中的有效性和泛化性。试验使用ADAM优化算法对模型损失函数进行参数优化, 学习率保持为0.01, 批大小为64。为保证试验的公平性与可比性, 所有模型的输入时间步长和输出时间步长将被一致固定为300和60。横摇监测系统采样频率为5 Hz, 对应单个时间步长为0.2 s。所有模型都是在TensorFlow-GPU框架内实现的。

2.2 试验评价指标

本文使用平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 作为评价标准, 公式为

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |p_{\text{rediction}i} - o_{\text{observed}i}| \quad (12)$$

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_{\text{rediction}i} - o_{\text{observed}i})^2} \quad (13)$$

式 (12) 和式 (13) 中: $p_{\text{rediction}i}$ 与 $o_{\text{observed}i}$ 分别为在

表 2 不同模型的船舶横摇运动误差对比

Tab. 2 Error Comparison of Ship Roll Motion Across Different Models

提前预报时长/s	LSTM		VMD-LSTM		VMD-LSTM-Attention	
	MAE/(°)	RMSE/(°)	MAE/(°)	RMSE/(°)	MAE/(°)	RMSE/(°)
3	0.593 1	0.761 9	0.559 1	0.719 7	0.489 6	0.640 3
6	0.725 9	0.927 4	0.692 7	0.888 0	0.631 3	0.814 4
9	0.937 4	1.188 4	0.850 4	1.128 6	0.764 8	0.943 3
12	1.114 3	1.416 2	1.054 5	1.338 8	0.894 1	1.133 4

结果显示, VMD-LSTM-Attention模型在大部分算例中预报精度均优于另外2种模型, 并且随着预报时间增加, 优势越明显。当预报时长为9 s时, VMD-LSTM模型对船舶横摇运动的MAE、RMSE比LSTM模型分别降低9.3%和11.8%; 当预报时长为12 s时, VMD-LSTM模型对船舶横摇运动的MAE、RMSE比LSTM模型分别降低5.4%和5.5%。VMD通过变分框架将信号分解为IMF, 每个IMF分量对应特定频带, 高频分量可视作噪声进行特殊处理或剔除; LSTM能够独立学习不同时间尺度的特征, 故VMD-LSTM模型比单一LSTM模型有更高的预报精度。在9 s预报时长下, 与VMD-LSTM模型相比, 引入注意力机制的VMD-LSTM-Attention模型对船舶横摇运动预报的MAE和RMSE分别降低10.1%与16.4%; 当预报时长延长至12 s时, 该模型的MAE和RMSE进一步降低, 降幅分别达到15.3%和17.6%。加入注意力机制后, VMD-LSTM-Attention模型能够通过输入特征施加自适应权重, 实现对关键信息的聚焦与强化, 从而在加深网络结构的同时, 提升对有效特征的利用效率。

相同时间点采集到的实船横摇运动观测序列与模型预测序列; N 为该时段内的总数据量。

定义预报的准确率为

$$A_{cc} = 1 - \left| 1 - \frac{A_{\text{rea}} \{o_{\text{observed}i} - M_{\text{ean}}(o_{\text{observed}i})\}}{A_{\text{rea}} \{p_{\text{rediction}i} - M_{\text{ean}}(p_{\text{rediction}i})\}} \right| \quad (14)$$

式中: $A_{\text{rea}}(\cdot)$ 为该段曲线与 X 轴围成的面积; $M_{\text{ean}}(\cdot)$ 为该段曲线的平均值。

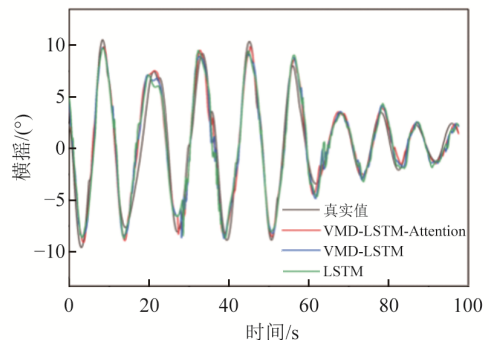
2.3 模型有效性验证

2.3.1 模型消融测试

为了评估VMD-LSTM-Attention模型的性能, 将VMD-LSTM-Attention模型的预报结果与LSTM模型和VMD-LSTM模型进行对比分析。特别提出, 本次工作的主要贡献在于通过消融试验深入解构所提出模型的内在机制, 而非进行广泛的基准测试。

表 2 列出了 LSTM 模型、VMD-LSTM 模型和 VMD-LSTM-Attention 模型的平均绝对误差和均方根误差。


该机制显著增强了模型对复杂时历模式的表达能力, 最终使其在预测任务中达到更高的精度。为了清楚地说明预测情形, 本文选择了一个横摇运动幅度较大的时历, 图10为提前预报时长6 s~12 s情况下船舶横摇运动预报结果对比。




(a) 各模型提前预报时长 6 s

图 10 各模型不同预报时长预报结果对比

Fig. 10 Comparison of Forecast Results Across Different Lead Times from Various Models



(b) 各模型提前预报时长 9 s



(c) 各模型提前预报时长 12 s


图 10 各模型不同预报时长预报结果对比 (续)

Fig. 10 Comparison of Forecast Results Across Different Lead Times from Various Models (Continued)


在9 s预报时长下, LSTM与VMD-LSTM模型的预测结果与真实值之间存在一定误差, 而VMD-LSTM-Attention模型则仍能保持较高的一致性。当预报时长延长至12 s时, 前2种模型的预测曲线已明显偏离真实值; 相比之下, VMD-LSTM-Attention模型的输出虽也出现一定偏差, 但仍能够有效跟踪真实变化趋势, 表现出更优的预测精度与稳定性。

为了进一步评估模型的预测稳定性, 本文对每个模型提前12 s预报条件下的预测误差进行了比较。每个模型的预测误差分布的直方图见图11。横轴表示误差值, 纵轴表示频数。误差分布直方图证明每个模型的预测误差分布是稳定的, 呈现近似对称的分布。本文对结果进行了高斯分布拟合。在高斯分布中, μ 为指平均值, 表示数据分布的中心。 σ 为高斯分布的离散程度。较大的 σ 表示数据点离均值更分散, 反之, 较小的 σ 表示数据点更集中在均值附近。VMD-LSTM-Attention模型预测误差分布的参数 $\sigma=1.13$, 在所有模型中是最小的, 表明VMD-LSTM-Attention的预测误差最为集中。此外, 模型的均值 μ 越接近0, 表明误差整体偏小、预测更稳定。综合误差分布特征, 各模型预测性能由优至

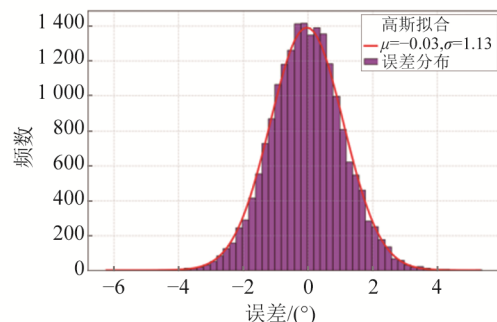
劣依次为: VMD-LSTM-Attention > VMD-LSTM > LSTM。



(a) LSTM 模型预测误差分布



(b) VMD-LSTM 模型预测误差分布



(c) VMD-LSTM-Attention 模型预测误差分布

图 11 各模型预测误差分布

Fig. 11 Distribution of Prediction Errors Across Various Models

2.3.2 不同海况下模型横摇预报的泛化性研究

中远海运的海图大数据系统可以通过卫星遥感数据、岸基雷达与船端传感器等多渠道来获取海况相关数据。在系统中, 0~2级海况为低海况, 有效波高在0~0.5 m; 3~5级为中海况, 有效波高为0.5 m~4.0 m; 6级以上为高海况, 其有效波高在4 m以上。现对1号船和2号船的数据集进行训练, 选取不同海况下3号船横摇运动时历进行测试, 使用定义的准确率评价预报效果, 以测试VMD-LSTM-Attention模型预报的泛化性。分析结果见图12。

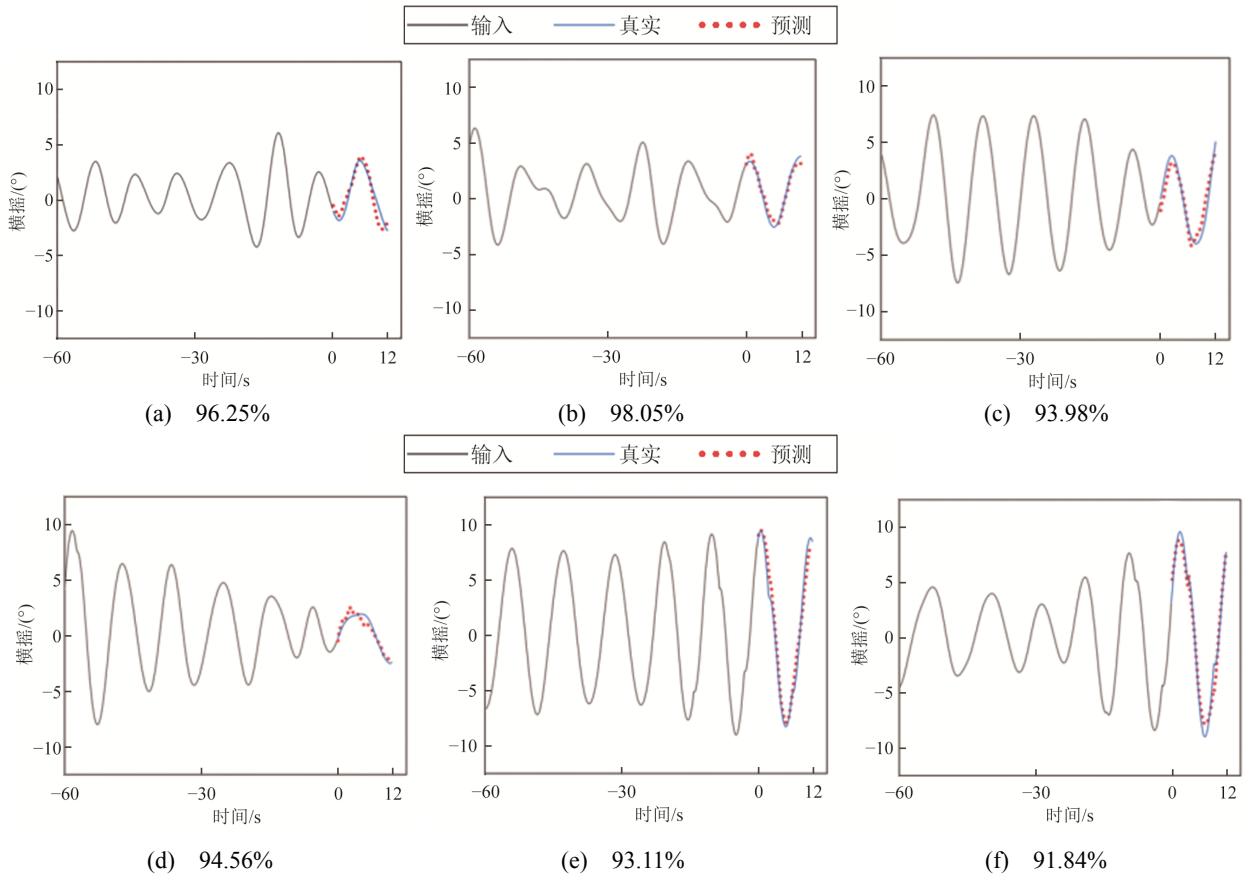


图 12 船舶横摇运动预报在测试集上的结果

Fig. 12 Forecast Results of Ship Rolling Motion on Test Set

结果显示, 文中使用的模型取得了良好的预报效果, 其低海况下预报准确率可以达95%以上, 中高海况下预报准确率达到90%。这是由于低海况下船舶运动更平稳, 数据噪声小, 神经网络更容易学习规律并且低海况样本占比更高。结果表明, 在不同海况下, 使用VMD-LSTM-Attention模型的船舶横摇运动的预报具有良好的泛化性。

3 结论

本文构建的VMD-LSTM-Attention混合模型可有效实现船舶横摇运动的极短期预报, 预报结果具有较高的准确性与可靠性, 在不同海况下表现出较强的泛化能力, 可为同类海洋时序预测任务提供参考。主要得出以下3点结论。

1) 与单一LSTM模型及VMD-LSTM模型相比, VMD-LSTM-Attention模型具有更优的特征学习与预报性能, 且随着预报时长的增加, 精度优势更为显著。这是因为LSTM能够独立学习由信号分解的IMF中不同时间尺度的特征, 加入注意力机制后, VMD-LSTM-Attention模型能够通过自适应权重分配机制, 聚焦于输入时序中的关键特征, 从而在加

深网络结构的同时, 提升对有效信息的感知与利用效率。

2) 在提前预报时长为12 s时, VMD-LSTM-Attention模型对横摇运动的预测误差: MAE为 0.89° 、RMSE为 1.13° 。与单一的LSTM模型和VMD-LSTM模型相比, 该模型的预报精度显著提高, 提升幅度达到15.3%以上。VMD-LSTM-Attention模型预测误差分布的参数 $\mu=-0.03$ 在所有模型中最靠近0、参数 $\sigma=1.13$ 在所有模型中是最小的, 进一步评估了模型的预报稳定性。

3) 对1号船和2号船的数据集进行训练, 选取不同海况下3号船横摇运动时历进行测试, 模型取得了良好的预报效果, 其低海况下预报准确率可以达到95%以上, 中高海况下预报准确率达90%。结果证明了VMD-LSTM-Attention模型在不同海况下船舶横摇运动的预报具有良好的泛化性。

当前工作在高频处理和跨频段注意力方面仍存在优化空间。现有的设计主要基于工程实用性和计算效率的考虑, 在保证预测性能的同时实现了较好的部署效果。

参考文献:

- [1] CHENG X, LI G, SKULSTAD R, et al. Data-Driven Uncertainty and Sensitivity Analysis for Ship Motion Modeling in Offshore Operations[J]. *Ocean Engineering*, 2019, 179: 261-272.
- [2] TRIANTAFYLLOU M, BODSON M, ATHANS M. Real Time Estimation of Ship Motions Using Kalman Filtering Techniques[J]. *IEEE Journal of Oceanic Engineering*, 1983, 8(1): 9-20.
- [3] TRIANTAFYLLOU M, ATHANS M. Real Time Estimation of the Heaving and Pitching Motions of a Ship, Using a Kalman Filter[C]//OCEANS 1981. 1981.
- [4] PENG X, ZHANG B, RONG L. A Robust Unscented Kalman Filter and its Application in Estimating Dynamic Positioning Ship Motion States[J]. *Journal of Marine Science and Technology*, 2019, 24(4): 1265-1279.
- [5] TAKAMI T, NIELSEN U D, JENSEN J J. Real-Time Deterministic Prediction of Wave-Induced Ship Responses Based on Short-Time Measurements[J]. *Ocean Engineering*, 2021, 221: 108503.
- [6] 马永艳, 姜志强, 汪训铭, 等. 一种基于 NGO 参数优化的 TCN-LSTM 船舶运动预报方法[J]. *中国造船*, 2025, 66(1): 187-197.
- MA Y Y, JIANG Z Q, WANG X M, et al. A Ship Motion Prediction Method Based on TCN-LSTM with NGO Parameter Optimization[J]. *China Shipbuilding*, 2025, 66(1): 187-197.
- [7] HUANG L M, DUAN W Y, HAN Y, et al. A Review of Short-Term Prediction Techniques for Ship Motions in Seaway[J]. *Journal of Ship Mechanics*, 2014, 18(12): 1534-1542.
- [8] XU C Z, ZOU Z J. Online Prediction of Ship Roll Motion in Waves Based on Auto-Moving Grid Search-Least Square Support Vector Machine[J]. *Mathematical Problems in Engineering*, 2021: 2760517.
- [9] 陈东洋. 面向船舶性能预报的增量学习方法研究[D]. 江苏无锡: 江南大学, 2024.
- CHEN D Y. Research on Incremental Learning Method for Ship Performance Prediction[D]. Wuxi, Jiangsu: Jiangnan University, 2024.
- [10] 刘煜城. 基于深度学习的船舶运动极短期预报方法研究[D]. 哈尔滨: 哈尔滨工程大学, 2019.
- LIU Y C. Research on Ultra-Short-Term Prediction Methods of Ship Motion Based on Deep Learning[D]. Harbin: Harbin Engineering University, 2019.
- [11] SILVA K M, MAKI K J. Data-Driven System Identification of 6-DoF Ship Motion in Waves with Neuralnetworks[J]. *Applied Ocean Research*, 2022, 125: 103222.
- [12] 李昊波, 肖龙飞, 魏汉迪, 等. 基于 LSTM 网络的浮式海洋平台运动在线预报研究[J]. *船舶力学*, 2021, 25(5): 576-585.
- LI H B, XIAO L F, WEI H D, et al. Online Motion Prediction of Floating Offshore Platforms Based on LSTM Network[J]. *Ship Mechanics*, 2021, 25(5): 576-585.
- [13] GUO X, ZHANG X, TIAN X, et al. Probabilistic Prediction of the Heave Motions of a Semi-Submersible by a Deep Learning Model[J]. *Ocean Engineering*, 2022, 247: 110578.
- [14] PENG X Y, ZHANG B, ZHOU H G. An Improved Particle Swarm Optimization Algorithm Applied to Long Short-Term Memory Neural Network for Ship Motion Attitude Prediction[J]. *Transactions of the Institute of Measurement and Control*, 2019, 41(15): 4462-4471.
- [15] 张睿, 孟帅, 张小卿, 等. 基于 LSTM 预训练-Transformer 修正的船舶运动极短期预报[J]. *船舶工程*, 2025, 47(4): 37-45.
- ZHANG R, MENG S, ZHANG X Q, et al. Short Term Prediction of Ship Motion Based on LSTM Pre Training Transformer Correction[J]. *Ship Engineering*, 2025, 47(4): 37-45.
- [16] WANG Y C, WANG H, ZHOU B, et al. Multi Dimensional Prediction Method Based on Bi-LSTMC for Ship Roll[J]. *Ocean Engineering*, 2021, 242: 110106.