

DOI:10.16356/j.1005-2615.2025.05.018

基于 LSTM 的舰载靶机适发窗口预报方法研究

戴 勇^{1,2}, 马智勇^{1,3}, 刘海瑞¹, 刘 浩¹, 章雨驰¹, 俞梦冉¹,
李 鹏¹, 钱征华¹, 李彤韡^{4,5}

(1. 南京航空航天大学航空学院, 南京 210016; 2. 中国融通集团第六十研究所, 南京 210016;
3. 海装驻南京地区第四军事代表室, 南京 211100; 4. 中国航空工业集团公司金城南京机电液压工程研究中心,
南京 211106; 5. 航空机电系统综合航空科技重点实验室, 南京 211106)

摘要: 为提高舰载靶机发射过程中船舶运动姿态的预测精度, 使用基于长短期记忆(Long short-term memory, LSTM)网络的船舶姿态预测方法。针对长时预测导致的误差累计问题, 提出了改进窗口滑动法, 通过对每次预测结果进行变分模态分解(Variational mode decomposition, VMD)滤波, 消除累积误差引起的预测结果振荡。通过有限元仿真及自主设计的船模实验平台开展波浪水池试验, 采集横摇、纵摇、垂荡等关键姿态参数的时序数据。实验设置涵盖 1 级至 5 级典型海况条件。实验结果表明, 该模型在升沉位移、横摇角及纵摇角预测中, 均方误差(Mean squared error, MSE)最大降幅可达 99.4%, MAPE 降低至 2.11%, 验证了其工程应用的有效性。研究成果可为舰载靶机发射引导系统提供高精度的船舶运动态势预判, 对提升着舰安全性具有重要工程价值。

关键词: 船舶; 长短期记忆网络; 姿态预测; 靶机发射

中图分类号: TP391

文献标志码: A

文章编号: 1005-2615(2025)05-0976-08

Research on Suitable Launch Window Prediction Method for Shipborne Target Aircraft Based on LSTM

DAI Yong^{1,2}, MA Zhiyong^{1,3}, LIU Hairui¹, LIU Hao¹, ZHANG Yuchi¹, YU Mengran¹,
LI Peng¹, QIAN Zhenghua¹, LI Tongwei^{4,5}

(1. College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;
2. The 60th Research Institute of CRTIC, Nanjing 210016, China; 3. The Fourth Military Representative Office of the Naval
Armament Department Stationed in Nanjing, Nanjing 211100, China; 4. AVIC Jincheng Nanjing Engineering Institute of
Aircraft System, Nanjing 211106, China; 5. Aviation Key Laboratory of Science and Technology on Aero Electromechanical
System Integration, Nanjing 211106, China)

Abstract: In order to improve the prediction accuracy of the ship's motion attitude during the launch of the carrier-based target drone, this paper uses a ship attitude prediction method based on the long short-term memory (LSTM) network. In view of the error accumulation problem caused by long-term prediction, this paper proposes an improved window sliding method, which eliminates the prediction result oscillation caused by the cumulative error by filtering each prediction result with variational mode decomposition (VMD). The

基金项目: 国家重点研发计划(2023YFEO111000); 国家自然科学基金(12172171, 12372151, 12061131013); 中央高校基本科研业务费资助项目(NS2022011); 航空航天结构力学及控制全国重点实验室自主研究课题(MCMS-I-0522G01); 江苏省自然科学基金(BK20211176); 江苏省双创计划资助项目(JSSCBS20210166); 航空科学基金(20200028052011)。

收稿日期: 2025-05-05; **修订日期:** 2025-06-04

通信作者: 钱征华, 男, 教授, 博士生导师, E-mail: qianzh@nuaa.edu.cn。

引用格式: 戴 勇, 马智勇, 刘海瑞, 等. 基于 LSTM 的舰载靶机适发窗口预报方法研究[J]. 南京航空航天大学学报(自然科学版), 2025, 57(5): 976-983. DAI Yong, MA Zhiyong, LIU Hairui, et al. Research on suitable launch window prediction method for shipborne target aircraft based on LSTM[J]. Journal of Nanjing University of Aeronautics & Astronautics (Natural Science Edition), 2025, 57(5): 976-983.

wave tank test was carried out through finite element simulation and a self-designed ship model experimental platform to collect time series data of key attitude parameters such as roll, pitch, and heave. The experimental setting covers typical sea conditions from level 1 to level 5. The experiment shows that the maximum mean squared error (MSE) reduction of the model in the prediction of heave displacement, roll angle and pitch angle is 99.4%, and the MAPE is reduced to 2.11%, which verifies the effectiveness of its engineering application. The research results can provide high-precision ship motion situation prediction for the launch guidance system of the carrier-based target drone, which has important engineering value for improving landing safety.

Key words: ship; long short-term memory (LSTM) network; attitude prediction; target drone launch

舰载机发射是海空协同作战体系中的高风险环节,其成功率高度依赖对甲板运动状态的实时感知与预测。船舶在复杂海况下的运动状态受波浪、风速、海流等多种因素的共同影响,其非线性、时变的动态特性使得传统基于物理模型或经典滤波方法的姿态预测在实时性与精度方面存在一定局限性^[1-2]。如何准确预测船舶在靶机着舰过程中的滚转、俯仰和纵摇等姿态变化,对保障着舰安全、提高舰载机作业效率具有重要意义。

船舶姿态预测方法中,时间序列分析方法较为常用,如自回归模型(Autoregression, AR)^[3-4],虽然该模型已得到了广泛的应用,但在面对非线性非平稳信号时表现仍不尽人意。近年来,随着人工智能和深度学习技术的迅速发展,长短期记忆(Long short-term memory, LSTM)网络凭借其在时序数据建模中的优势,已在语音识别、金融预测、气象预报、材料学等领域取得了显著成果^[5-11]。LSTM能够有效捕捉时间序列中长时间依赖关系,较好地处理数据中的非线性和时变特性,为复杂动态系统的预测提供了一种新的思路。为解决单一模型预测的局限性,彭秀艳等^[12]提出一种基于经验模态分解(Empirical mode decomposition, EMD)和粒子群优化(Particle swarm optimization, PSO)的LSTM网络的组合预测模型,有效提高了船舶运动姿态预测精度。夏骏达等^[13]为解决因船舶姿态信号采集、处理环节带来的时滞问题,利用EMD将非线性非平稳的船舶运动姿态信号分解为若干个本征模函数(Intrinsic mode function, IMF)和残差信号,再通过LSTM学习各IMF分量和残差信号的短期时序规律并进行预测。相较于AR、LSTM等单一预测模型,该模型的预测精度有明显提高。

上述论文中均未提及预测较长时间窗口内因预测滑动窗口造成的累积误差如何抑制,在使用滑动窗口法对后几步船舶姿态进行预测时,模型会捕

提前几步预测产生的误差,放大预测误差,导致结果出现快速振荡。为解决这一问题,本文采用变分模态分解(Variational mode decomposition, VMD)对每一步网络输入进行滤波处理,消除噪声及预测误差带来的影响,提高预测精度及准确度,为靶机发射进行准确的适发窗口预报。

1 变分模态分解

VMD是一种基于变分框架的自适应信号处理方法,旨在将复杂信号高效地分解为若干具有特定中心频率和有限带宽的IMF^[14]。与传统EMD相比,VMD通过引入约束优化模型,有效克服了模态混叠、端点效应及噪声敏感等问题,尤其适用于非平稳、非线性信号的时频分析。其核心思想是通过构建变分问题,在保证分解模态之和等于原始信号的前提下,最小化各模态的估计带宽之和。

假设待分解信号为 $f(t)$,分解的目标是将 $f(t)$ 分解为 K 个IMF分量 $\{u_k(t)\}_{k=1}^K$,并为每个模态分配一个中心频率 $\{\omega_k\}_{k=1}^K$ 。对每个模态先利用希尔伯特变换构造其解析信号,再将其频谱平移至零频处,使得各模态均集中于低频区域,并通过带宽估计的方式使得每个模态具有有限带宽。最终,原始优化问题可表述为

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

满足分解约束: $\sum_{k=1}^K u_k(t) = f(t)$ 。其中: $\delta(t)$ 为狄拉克脉冲函数; $e^{-j\omega_k t}$ 用于将 $u_k(t)$ 的频谱平移,使其中心频率归零,从而便于估计其带宽。

为了便于求解,通常将上述带有等式约束的优化问题转化为无约束问题,通过引入惩罚项和拉格朗日乘子构造增广拉格朗日函数。设惩罚参数为 α ,拉格朗日乘子为 $\lambda(t)$,则增广拉格朗日函数可写为

$$\mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) =$$

$$\begin{aligned} & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \\ & \int_{-\infty}^{\infty} \lambda(t) \left(f(t) - \sum_{k=1}^K u_k(t) \right) dt \end{aligned} \quad (2)$$

通过交替方向乘子法 (Alternating direction method of multipliers, ADMM), 对上述目标函数进行交替迭代更新, 可以分别求得各模态 $u_k(t)$ 和中心频率 ω_k 的最优解。

2 LSTM 神经网络

LSTM 是一种改进的循环神经网络 (Recurrent neural network, RNN) 结构^[15], 专门设计用于捕捉序列数据中的长期依赖关系, 克服传统 RNN 在长序列学习过程中容易出现的梯度消失或梯度爆炸问题。LSTM 通过引入记忆单元 (cell) 和门控机制, 能够在信息传递过程中自动选择性地保留或遗忘关键信息, 从而显著提升模型在时序数据处理、自然语言处理、语音识别等领域的表现。

在 LSTM 神经网络中, 每个时间步 t 的计算过程主要是将当前输入数据 x_t 与前一时刻的隐状态 h_{t-1} 结合, 通过一系列的线性变换和非线性激活操作, 最终生成新的记忆单元状态 C_t 和输出隐状态 h_t 。具体包括: 首先进行数据拼接, 将当前时刻输入 x_t 与前一时刻的隐状态 h_{t-1} 进行拼接, 记为 $z_t = [h_{t-1}, x_t]$; 然后遗忘门 (Forget gate) 进行作用, 通过线性变换后, 利用 Sigmoid 函数将输出压缩到 $[0, 1]$ 区间, 即

$$f_t = \sigma(W_f \cdot z_t + b_f) \quad (3)$$

式中: W_f 为遗忘门的权重矩阵, b_f 为偏置项。输出 f_t 的每个元素表示对应记忆单元成分需要保留的比例。

然后由输入门决定哪些新信息将加入到记忆中: $i_t = \sigma(W_i \cdot z_t + b_i)$, 同时通过候选记忆单元生成新信息

$$\tilde{C}_t = \tanh(W_C \cdot z_t + b_C) \quad (4)$$

式中: W_i 、 W_C 分别为输入门和候选记忆单元的权重矩阵, b_i 、 b_C 为相应的偏置项。这里的 $\tanh$ 激活函数将候选记忆值映射到 $[-1, 1]$ 范围内。

然后利用遗忘门和输入门的输出, 更新记忆单元状态 C_t , 即

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (5)$$

式中“ $\odot$ ”表示逐元素相乘。该步骤体现了 LSTM

如何在保留之前的信息与引入新信息之间取得平衡。

最后, 输出门决定了当前时刻的输出信息: $o_t = \sigma(W_o \cdot z_t + b_o)$, 最后, 利用更新后的记忆单元状态生成新的隐状态, 即

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

这里先对 C_t 应用 $\tanh$ 激活函数, 然后再与输出门 o_t 的结果逐元素相乘, 从而得到当前时刻的输出 h_t 。

这种逐步计算的过程, 使得 LSTM 能够有效捕捉长时序信息, 并在每个时间步灵活控制信息的遗忘和保留, 从而大大改善了传统 RNN 在长序列处理中的梯度消失问题。

3 基于 VMD-LSTM 的修正滑动窗口组合模型

由于 LSTM 在一次预测多秒数据时会出现预测误差过大的问题, 因此在一次进行多秒预测时, 往往采用滑动窗口预测, 即每次只预测未来 1 s 的船舶姿态, 然后将新预测的 1 s 数据和已有真实数据进行拼接 (进行拼接而不是全部使用新预测出的数据是为了最大程度保留真实数据), 形成新的网络输入, 预测出下 1 s 的数据, 以此类推, 直至预测出所有数据。但在实际使用过程中发现, 在进行数据拼接时, 在拼接处左边的真实结果 (比如第 24 s 船舶姿态) 和右边预测的结果 (第 25 s 船舶姿态) 之间会存在一点梯度突变, 滑动过后网络作为网络输入时, LSTM 网络会学习到这个梯度并认为它是海况变化引起的突变趋势从而进行放大, 这在只进行几次滑动时对结果没有明显影响, 但在进行多次滑动时会导致每次预测结果出现剧烈振荡, 结果严重失真, 因此为抑制这种失真, 本文对每次预测结果进行 VMD 滤波, 去除每次预测结果中的小梯度变化, 只保留信号的本征模态, 这可以很好抑制这种误差。具体的流程图如图 1 所示。

具体流程伪代码如算法 1 所示。

算法 1 基于 LSTM 的姿态预测

输入: 采集的姿态数据 $t_1 \sim t_{24}$

输出: 预测的姿态状态 $t_{25} \sim t_{32}$

(1) 数据采集:

采集 24 s 的姿态数据 $t_1 \sim t_{24}$, 包括横摇、纵摇和升沉。

(2) 数据预处理:

采用 VMD 去除高频噪声。

将数据划分为训练集 (80%) 和测试集 (20%)。




图1 基于VMD-LSTM的修正滑动窗口组合模型预测流程图

Fig.1 Modified sliding window combined model prediction flow chart based on VMD-LSTM

- (3) LSTM 模型训练:
构造输入序列 $t_1 \sim t_{24}$ 。
训练 LSTM 模型以捕捉时序依赖关系。
- (4) 迭代预测:
初始化输入序列 $X=[t_1, t_2, \dots, t_{24}]$ 。
对于 $i=25$ 到 32 执行:
使用 LSTM 预测 t_i :
 $[\tilde{t}_2, \tilde{t}_3, \dots, \tilde{t}_{25}]=\text{LSTM}(X)$
 $[\tilde{t}_2, \tilde{t}_3, \dots, \tilde{t}_{25}]=\text{VMD}([\tilde{t}_2, \tilde{t}_3, \dots, \tilde{t}_{25}])$
 $X=[\tilde{t}_2, \tilde{t}_3, \dots, \tilde{t}_{25}]$
- (5) 输出预测的姿态状态:
返回 $[\tilde{t}_{25}, \tilde{t}_{26}, \dots, \tilde{t}_{32}]$ 。




图2 水池实验环境及配置

Fig.2 Pool experiment environment and configuration

4 实验结果及分析

4.1 船舶运动实验数据

本实验采用比例为 1:35 的 054A 舰船模缩比模型,在带有造波机的水池中进行。实验中为了准确捕捉船模的横摇和纵摇随时间的变化,在船模上安装了角度传感器和位移传感器,实时测量船模的横摇(左右晃动)与纵摇(前俯后仰)及升沉。实验过程中在水池的一端设置了造波机,按照国标规定的波浪谱生成随机波浪,用于生成所需的不规则波浪,满足实际工况中不同波高、不同周期的需求。同时,在来流方向布置了风扇,产生与波浪相匹配的风速,确保实验条件接近真实的风浪环境。实际风速和波高通过弗劳德相似准则(Froude similarity)换算成实验风速和波高,以模拟 054A 舰船在实际工况下的运动。具体实验环境配置如图 2 所示。

实验的具体工况如表 1 所示,实验选取了 1~5 级海况,每种工况下的来流方向分别为 0°、60°、90°、150°和 180°,吨位选择为 3 000~6 000 t。这期间,通过在船体前部和后端增加质量配重来代表不同吨位的工况。实验过程中一共选择了 175 组工况,每组采集大于 1 200 s 的数据。

表 1 实验工况设置				
Table 1 Experimental condition setting				
海况等级	实际风速/ (m·s ⁻¹)	实验风速/ (m·s ⁻¹)	实际波高/ m	实验波高/ m
1	3.9	0.66	0.60	0.017
2	5.5	0.93	1.00	0.028
3	6.9	1.17	1.25	0.036
4	8.0	1.35	1.50	0.043
5	9.4	1.59	2.00	0.057

4.2 数据处理

因为数据在采集过程中存在许多外界的电磁等噪声干扰,所以首先通过VMD分解对信号进行滤波操作,只保留分解后的第一个本征模态作为网络的输入进行姿态预测。然后将滤波后的数据集划分出80%用来训练模型(70%用作训练集,10%用作验证集),剩下的20%用作测试集。在进行仿真之前还需要对数据进行归一化,加快计算速度和收敛稳定性,归一化公式如下

$$M_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (7)$$

式中: $x_i(i=1,2,\dots,n)$ 为输入的数据, $x_{\max}$ 为数据中的最大值, $x_{\min}$ 为数据中的最小值, M_i 为归一化后的数据。

4.3 预测结果及误差分析

在使用VMD-LSTM时,VMD算法分解出的模态数 K 为2,可以分解出船舶主要运动姿态,惩罚因子 α 设置为2 000,值越大模态的带宽越窄、更聚焦。经过网格搜索尝试后,LSTM网络参数设置如下,采用了4个隐藏层,每层118个神经元,遗忘参数drop out为0.5,批次batch size大小设置为64,此时网络训练收敛速度最快。网络训练过程中学习率的设置采用逐级递减的方法,即前200步学习率设置为 $1e-4$,随后每过200步学习率下降一半,直至600步后停止训练,优化器采用Adam。滑动窗口长度1 200,每次滑动步长50,共滑动8次,预测结果长度400。

在预测模型的性能评估中,多种指标被用于量化预测值与真实值之间的偏差。采用均方误差(Mean squared error, MSE)和平均绝对百分比误差(Mean absolute percentage error, MAPE)作为核心评估指标,以全面衡量模型的预测精度与稳健性,同时决定系数(Coefficient of determination, R^2)被用来评价模型的整体拟合能力。MSE、MAPE和 R^2 的计算公式分别如下

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$


$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

式中: n 为模型预测输出的样本数量, y_i 为第 i 个真实值, $\hat{y}_i$ 为第 i 个预测值, $\bar{y}$ 为真实值的均值。


同时采用MSE与MAPE,前者捕捉模型对大

幅偏差的控制能力,后者评估预测结果的相对一致性。二者的结合可避免单一指标的片面性,为模型优化提供多维参考。同时使用 R^2 来评价模型的整体预测效果,实现全方位的准确评估。


LSTM与VMD-LSTM模型在船舶姿态预测中的表现如图3所示。从横摇角(图3(a))和纵摇角(图3(b))的预测曲线可见,VMD-LSTM的预测值更贴近真实值轨迹,且波动幅度显著降低,尤其在样本索引中后段(100~300区间),LSTM预测值因滑动窗口拼接过程中带来干扰较大,而VMD-LSTM通过变分模态分解有效抑制了窗口拼接过程中带来的误差,提升了预测稳定性。这一结论在误差分析中进一步量化:VMD-LSTM的预测误差绝对值始终低于0.05(表2),而LSTM误差最大达到0.15,且呈现周期性振荡(样本索引150~220区间),表明模态分解优化了误差传播机制。



(a) Roll angle prediction results



(b) Pitch angle prediction results



(c) Heave displacement prediction results

—真实值; —LSTM预测值; —VMD-LSTM滤波后的预测值

图3 船舶姿态预测结果

Fig.3 Ship attitude prediction results

表 2 的统计结果从多维度验证了上述结论。在横摇角预测中,VMD-LSTM 的 MSE(359.32×10^{-6}) 较 LSTM ($1\,294.73\times 10^{-6}$) 降低 72.2%,MAPE 由 1.31% 降至 0.86%;纵摇角预测中,MSE 降幅达 83.0% (18.09×10^{-6} vs. 106.31×10^{-6}),MAPE 从 0.13% 优化降至 0.05%;升沉位移的改进尤为显著,MSE 从 120.66×10^{-6} 降至 0.70×10^{-6} (降幅 99.4%),MAPE 由 7.49% 降至 2.11%。这些数据表明,VMD-LSTM 在位移、角度等多维度预测中均实现了误差的全面缩减,尤其在升沉位移这类易受噪声干扰的参数上,其鲁棒性表现突出。而 VMD-LSTM 在横摇角和升沉位移上相较于 LSTM 的 R^2 均上升到了 0.9 以上,可以反映出网络在模型整体预测能力上均有较好的提升。

表 2 预测误差统计结果			
Table 2 Prediction error statistics			
姿态		LSTM	VMD-LSTM
横摇角	MSE/ 10^{-6}	1 294.73	359.32
	MAPE/%	1.31	0.86
	R^2	0.870 5	0.964 1
纵摇角	MSE/ 10^{-6}	106.31	18.09
	MAPE/%	0.13	0.05
	R^2	0.989 4	0.998 2
升沉位移	MSE/ 10^{-6}	120.66	0.70
	MAPE/%	7.49	2.11
	R^2	0.793 4	0.993 0

进一步结合图 4 的预测误差图分析,LSTM 与 VMD-LSTM 的误差分布集中在对角线下方,表明 85% 以上的样本中改进模型的预测误差更小,最大误差降低幅度达 67%。综合图表可知,VMD-LSTM 的核心优势在于:通过变分模态分解剥离信号中的拼接带来的突变干扰,增强 LSTM 对时序核心特征的捕捉能力;同时,分解后的子信号重构优化了模型输入的平稳性,从而显著降低了误差的累积与传播。该方法不仅提升了预测精度,还为船舶运动控制的实时性与可靠性提供了技术保障。

4.4 讨论分析

提出的高精度船舶姿态预测模型(VMD-LSTM)的核心应用目标是为舰载靶机发射提供准确的适发窗口预报。适发窗口是指满足靶机安全发射条件、船舶运动姿态相对平稳的连续时间段,其预报流程基于以下关键步骤:

(1) 实时姿态预测。利用训练完成的 VMD-LSTM 模型,基于当前及历史船舶运动姿态时序数据(横摇角、纵摇角、升沉位移),对未来一段




图 4 船舶姿态预测结果误差
Fig.4 Ship attitude prediction result error

时间(如预测步长 400 对应的实际时长)的姿态参数进行滚动预测。

(2) 安全阈值设定。根据舰载靶机的型号、发射装置特性以及安全操作规程,设定关键姿态参数的安全阈值。这些阈值通常包括:最大允许横摇角(Roll_max)以确保发射平台横向稳定性;最大允许纵摇角(Pitch_max)以确保发射方向准确性;最大允许升沉位移(Heave_max)或其变化率以确保发射瞬间垂直方向的平稳性;最小稳定持续时间(T_{min})以要求姿态参数连续保持在阈值范围内的最短时间,以满足发射操作流程需求。

(3) 窗口判断算法。对预测得到的未来姿态序列进行分析:扫描预测序列,识别所有满足 $\text{Roll} < \text{Roll}_{max}$, $\text{Pitch} < \text{Pitch}_{max}$, $\text{Heave} < \text{Heave}_{max}$ (或满足其他判据如升沉速度、加速度阈值)的时间点。将连续的满足条件的时间点合并为潜在的适发时间段。筛选出其中持续时间 $\geq T_{min}$ 的时

间段,作为预报的适发窗口

(4) 输出预报结果。将识别出的适发窗口(起始时间、结束时间、预测持续时间)以及对应的预测姿态曲线,输出给舰载靶机发射引导系统,为指挥员提供决策支持。

5 结 论

本文提出的 VMD 优化滑动窗口法可以帮助 LSTM 提升预测精度与稳定性。该方法通过对每次窗口滑动后构建的新模型输入数据进行滤波,达到减少每次预测误差带来的累积效应。实验结果表明,该模型在升沉位移、横摇角及纵摇角预测中,均比传统 LSTM 效果更好,尤其后半预测结果精度显著提高,大大减小了滑动预测带来的误差累积,验证了其工程应用的有效性。此算法有效解决了传统方法在长时预测中误差累积放大的问题,为适发窗口预报提供了可靠的数据输入,从而最终实现了对适发窗口更准确、更可信的预报能力。

尽管如此,船舶姿态预测技术仍面临以下挑战:复杂海况下多源干扰的实时滤除问题、模型轻量化与计算效率的平衡、多模态数据融合机制的优化,以及缺乏统一的可推广性评价体系与标准化验证流程。未来研究可以针对开发自适应噪声抑制算法以增强模型泛化能力,增强算法实时性和实用性。以期能为船舶智能控制系统的优化提供理论支撑,并促进高精度、高可靠性姿态预测技术的工程化应用。

参考文献:

- [1] 左思雨,赵强,张冰,等.基于 VMD-SSA-GRU 的船舶运动姿态预测[J].舰船科学技术,2022,44(23): 60-65,69.
ZUO Siyu, ZHAO Qiang, ZHANG Bing, et al. Prediction of ship motion attitude based on VMD-SSA-GRU model[J]. Ship Science and Technology, 2022, 44(23): 60-65,69.
- [2] 谷达京,施哲源,陈根良,等.基于神经网络的船体运动位姿预测方法[J].舰船科学技术,2022,44(15): 55-59.
GU Dajing, SHI Zheyuan, CHEN Genliang, et al. Deep learning for predicting ship motion from images, pitches and rolls[J]. Ship Science and Technology, 2022, 44(15): 55-59.
- [3] HUANG Liming, 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): 1033-1049.
- [4] 段海滨,袁洋,张秀林.干扰和执行器故障下的舰载机着舰容错控制系统[J].南京航空航天大学学报,2022,54(5): 949-957.
DUAN Haibin, YUAN Yang, ZHANG Xiulin. Design of a carrier-based aircraft landing fault-tolerant control system with disturbances and actuator faults [J]. Journal of Nanjing University of Aeronautics & Astronautics, 2022, 54(5): 949-957.
- [5] 胡晓彤,程晨.基于多维度跨尺度 LSTM 模型的时序预测[J].计算机工程与设计,2023,44(2): 440-446.
HU Xiaotong, CHENG Chen. Time series prediction based on multi-dimensional and cross-scale LSTM model[J]. Computer Engineering and Design, 2023, 44(2): 440-446.
- [6] 张莉,许世辉,李承桓,等.基于 LSTM 网络优化的电力客服语音情感识别系统[J/OL].自动化技术与应用,1-6[2025-02-08].<http://kns.cnki.net/kcms/detail/23.1474.TP.20241230.1012.091.html>.
ZHANG Li, XU Shihui, LI Chengheng, et al. Power customer service speech emotion recognition system based on LSTM network[J]. Techniques of Automation and Applications, 1-6[2025-02-08]. <http://kns.cnki.net/kcms/detail/23.1474.TP.20241230.1012.091.html>.
- [7] 孙娜,周绍伟,潘姿宇.基于 XGBoost-LSTM 模型的多特征股票价格预测研究[J].数学建模及其应用,2023,12(4): 32-39.
SUN Na, ZHOU Shaowei, PAN Ziyu. Research on multi-characteristic stock price forecast based on XGBoost-LSTM model[J]. Mathematical Modeling and Its Applications, 2023, 12(4): 32-39.
- [8] 郭永,王冰,陈玉全,等.融合精细化气象因素与物理约束的深度学习模型在短期风电功率预测中的应用[J].电网技术,2024,48(4): 1455-1468.
WU Yong, WANG Bing, CHEN Yuquan, et al. Application of deep learning model integrating refined meteorological factors and physical constraints in short-term wind power prediction[J]. Power System Technology, 2024, 48(4): 1455-1468.
- [9] 郭力,郑良瑞,冯浪.基于相关性分析与 CNN-BiLSTM 神经网络的 PSZ 陶瓷磨削表面粗糙度智能预测[J].南京航空航天大学学报,2023,55(3): 401-409.
GUO Li, ZHENG Liangrui, FENG Lang. Intelligent prediction of PSZ ceramic grinding surface roughness based on correlation analysis and CNN-BiLSTM neural network[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(3): 401-409.
- [10] 庞聪,连海伦,周健,等.一种基于特征融合的耳语音向正常音的转换方法[J].南京航空航天大学学报,2020,52(5): 777-782.
PANG Cong, LIAN Hailun, ZHOU Jian, et al.

Method for transforming whisper to normal speech with feature fusion[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2020, 52(5): 777-782.

[11] 崔翼扬,陈普会. 基于深度学习的复合材料开孔板拉伸失效行为预测[J].南京航空航天大学学报, 2024, 56(3): 468-477.

CUI Yiyang, CHEN Puhui. Prediction of tensile failure behavior of open-hole composite plates based on deep learning[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2024, 56(3): 468-477.

[12] 彭秀艳,张彪. 基于 EMD-PSO-LSTM 组合模型的船舶运动姿态预测[J].中国惯性技术学报, 2019, 27(4): 421-426.

PENG Xiuyan, ZHANG Biao. Ship motion attitude prediction based on EMD-PSO-LSTM integrated model[J]. Journal of Chinese Inertial Technology, 2019, 27(4): 421-426.

[13] 夏骏达,郑伟伦,王子涵,等. 基于 EMD-LSTM 的船舶运动姿态短期预测[J].计算机与数字工程, 2022, 50(7): 1434-1438.

XIA Junda, ZHENG Weilun, WANG Zihan, et al. Short-term prediction of ship motion attitude based on EMD-LSTM[J]. Computer & Digital Engineering, 2022, 50(7): 1434-1438.

[14] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.

[15] YU Y, SI X, HU C, et al. A review of recurrent neural networks: LSTM cells and network architectures [J]. Neural Computation, 2019, 31(7): 1235-1270.

(编辑:夏道家)