

文章编号: 1007-7294(2025)09-1383-14

一种改进的 LSTM 船舶运动极短期预报方法

洪智超^{1,5}, 丁羿杰¹, 刘 蕾², 王 浩^{3,4}, 张卫伟^{3,4}, 徐立新^{1,5}

(1. 江苏科技大学, 江苏 镇江 212100; 2. 中国造船工程学会, 北京 100861; 3. 南通鹏瑞海工科技有限公司, 江苏 南通 226000; 4. 南通集海海洋装备有限公司, 江苏 南通 226100; 5. 江苏省船舶与海洋工程装备技术创新中心, 江苏 南通 226100)

摘要: 船舶与海洋结构物的运动是具有时间序列特性的非线性运动, 而长短期记忆人工神经网络(Long Short-Term Memory, LSTM)具有记忆时间间隔信息以及处理非线性数据的特性, 非常适合处理此类具有时间序列特性的非线性运动, 所以 LSTM 对船舶极短期运动响应预报具有显著优势。本文提出一种改进的 LSTM 船舶极短期运动响应预报方法, 该方法通过提取包络线等手段将对船舶运动的预报转化为峰谷值的预报, 可以降低传统 LSTM 模型的数据需求量, 简化预报曲线复杂度, 从而显著提高预报时长。本文通过用改进 LSTM 模型对规则波曲线、不规则波曲线、实体船运动曲线等进行预报, 结果表明, 改进的 LSTM 预报方法能将传统 LSTM 模型对不规则波的最大预报时长从 6~8 s 提升到 20 s 左右, 且对突变信号等特殊信号有理想的预报结果, 具有很高的实用价值。

关键词: LSTM; 船舶运动; 极短期预报; 包络线分析

中图分类号: U671.99 **文献标识码:** A **doi:** 10.3969/j.issn.1007-7294.2025.09.005

An improved LSTM method for extremely short-term forecasting of ship movement

HONG Zhi-chao^{1,5}, DING Yi-jie¹, LIU Lei², WANG Hao^{3,4}, ZHANG Wei-wei^{3,4}, XU Li-xin^{1,5}

(1. Jiangsu University of Science and Technology, Zhenjiang 212100, China; 2. China Shipbuilding Engineering Society, Beijing 100861, China; 3. Nantong Pengrui Offshore Engineering Co., Ltd., Nantong 226000, China; 4. Nantong Jihai Marine Equipment Co., Ltd., Nantong 226100, China; 5. Jiangsu Provincial Technology Innovation Center for Shipbuilding and Offshore Engineering Equipment, Nantong 226100, China)

Abstract: The motion of ships and marine structures is a nonlinear motion with time series characteristics. The Long Short-Term Memory (LSTM) artificial neural network has the characteristics of memorizing time interval information and processing nonlinear data, which is very suitable for processing such nonlinear motion with time series characteristics. Therefore, LSTM has significant advantages in predicting the very short-term motion response of ships. In this paper, an improved LSTM method for the prediction of very short-term motion response of ships is proposed. This method converts the prediction of ship motion into the prediction of peak and valley values by means of extracting envelopes, which can reduce the data demand of the traditional LSTM model and simplify the complexity of the prediction curve, thereby significantly improving the forecast duration. In this paper, the improved LSTM was used to predict the regular wave curve, irregular wave curve and real ship motion curve. The results show that the improved LSTM prediction method can enlarge the maximum forecast duration of the traditional LSTM model from 6~8 s to about 20 s,

收稿日期: 2025-03-15

基金项目: 国家重点研发计划资助项目(2022YFC2806600; 2022YFC2806604)

作者简介: 洪智超(1987-), 男, 博士, 副教授, E-mail: hzciavip@163.com;

徐立新(1966-), 男, 博士, 教授, 通讯作者, E-mail: Lxu@just.edu.cn。

and has ideal prediction results for special signals such as abrupt signals, which has high practical value.

Key words: LSTM; ship movement; very short-term forecast; envelope line analysis

0 引言

船舶等海面浮体在海上风浪组合的复杂环境中,会产生六个自由度的运动,而对船舶平稳性要求较高的海上精密作业,如航母舰载机着舰、船舶吊装作业等,剧烈的运动会使海上作业人员产生极大的影响,为避免此类影响造成作业安全事故的发生,作业人员需要能准确把握船舶未来的运行情况,从而保证作业安全性和作业效率,而船舶运动姿态极短期预报就是一个重要的研究方向^[1]。

长短期记忆神经网络(Long Short-Term Memory, LSTM)模型非常适用于船舶运动、波浪等参数的极短期预报,相较于过去基于物理运算的极短期预报模型,基于 LSTM 的极短期预报模型具有计算量小、运算速度快、成本低等优势^[2],但长期以来,由于 LSTM 算法自身局限、误差累积等原因,此类方法的预报精度随时间下降较快,有效的预报时长短,难以在实际场景中应用^[3]。近年来随着智能算法的进一步普及和拓展,一些基于改进 LSTM 的极短期预报方法成为主要研究方向,这类方法能结合 LSTM 模型与其他智能算法模型的优缺点,取长补短,并针对预报数据进行去噪、降维等处理降低复杂度,一定程度上能解决单一智能算法有效预报时长短、抗干扰性弱等问题。目前基于改进 LSTM 算法进行的极短期预报已有诸多研究,如上海交通大学潘文寅等^[4]利用多平台混合训练 LSTM 模型,实现了对未来 20~40 s 内的垂荡和纵荡运动的精确预报。吴成东等^[5]将 LSTM 模型与经验模态分解(EMD)方法结合,将预报结果的平均绝对百分比误差缩小至 5% 以内,明显优于传统 LSTM 预报模型。哈尔滨工程大学唐忠^[6]将高斯过程回归算法(GPR)引入到船舶运动姿态极短期预报问题中,采用两步预测的思想,成功结合了 LSTM 和 GPR 各自的优势,得到的预报结果能在不损失 LSTM 模型预报精度的同时获得更可靠的区间预测结果等。对 LSTM 本身进行改进的极短期预报模型也取得了较大进展,如张承维^[7]提出了一种融合注意力机制的双向 LSTM 模型,通过动态加权关键时间步的特征,显著提高了不规则波的预报精度,使其有效预报时长达到 15 秒。李明瑞^[8]创新性地经验模态分解(EMD)与 LSTM 相结合,先通过 EMD 分解波浪信号的各模态分量,再利用 LSTM 对各分量分别建模预报,该方法在非线性波浪预报中较传统 LSTM 误差降低了 23% 等。

本文在前人研究的基础上,提出一种结合包络线的 LSTM 极短期预报方法,该方法通过简化预报数据复杂度以提高 LSTM 训练效率,最终提高 LSTM 的有效预报时长。

1 LSTM 极短期预报方法

1.1 长短期记忆(LSTM)神经网络算法

LSTM 算法由细胞状态传输信息和“门”结构管理信息构成,其中“门”结构包括遗忘门、输入门和输出门,分别负责筛选旧信息、更新细胞状态和决定输出重要信息。遗忘门通过激活函数决定数据保留或舍弃,输入门创造新的候选值向量,输出门则选择并输出重要信息^[7]。LSTM 的具体结构和数据传播方式如图 1 所示。




图 1 LSTM 单元结构图

Fig.1 Structure diagram of LSTM unit

LSTM 主要参数设置如下: LSTM 隐藏层为单层结构, 隐藏节点数 600, 优化器选择 Adam(自适应矩估计), 初始学习率设置为 0.005, 训练迭代轮数为 2000, 最大训练批次大小为 32。初始训练样本数设置为样本总量的 80%, 测试样本数设置为样本总量的 20%, 输出采用滑动时间窗迭代多步输出, 窗口大小为 10。

本文中 LSTM 模型的样本数据来源于数值仿真与实船试验, 涵盖规则波、近似规则波、JONSWAP 谱不规则波及突变工况等, 内容覆盖典型及极端工况以保证数据的代表性。样本库数据按照 8 : 2 划分训练集和测试集, 经 Min-Max 归一化和滑动窗口预处理, 并采用 K=5 交叉验证其泛化能力, 保证了神经网络算法训练的可靠性。

1.2 改进 LSTM 极短期预报方法

船舶摇荡等运动曲线通常存在较强的周期性, 且振幅、频率变化趋势相对恒定, 变化范围较小^[10], 因此本文对 LSTM 算法预报流程进行改进。首先, 分别将船舶运动曲线的波峰和波谷值连接成曲线, 形成包络线, 将对船舶运动曲线的预报问题转化为对包络线的预报问题(见图 2), 从而大幅降低 LSTM 训练和计算量, 提高预报效率和精度。

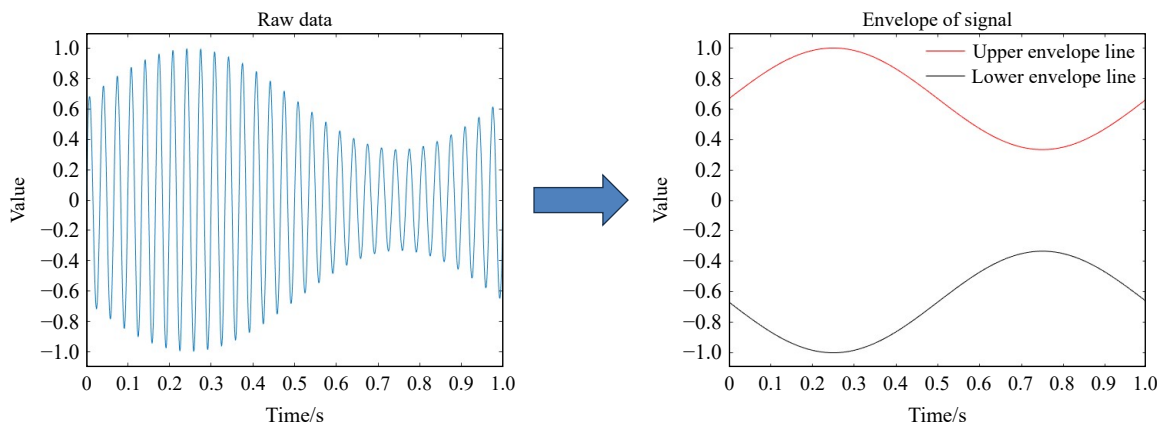


图 2 船舶运动数据模拟信号和其包络线的复杂度对比

Fig.2 Comparison of the complexity of ship motion data between analog signals and their envelopes

包络线可通过对原始数据曲线进行 Hilbert 变换得到。Hilbert 变换方程为

$$H(f(x)) = \frac{1}{\pi} P.V. \int_{-\infty}^{\infty} \frac{f(t)}{t-x} dt \tag{1}$$

式中, $f(x)$ 为原始信号, $H(f(x))$ 为信号 $f(x)$ 的 Hilbert 变换, $P.V.$ 表示柯西主值。

包络线即为 $H(f(x))$ 的模, 即

$$g(x) = |H(f(x))| = \sqrt{H(f(x)) \cdot H^*(f(x))} \tag{2}$$

式中, $g(x)$ 即为信号 $f(x)$ 的包络线函数。

要将包络线还原为原始曲线, 需要得到能描述原始曲线随时间变化的函数关系, 并将曲线的幅值、周期作为参数嵌入其中。已有研究表明, 船舶运动曲线、波浪曲线存在正弦波、正态波等周期信号的特征^[11], 因此可以通过非线性回归的方式, 将原始信号曲线转化为以时间为自变量, 振幅、周期为参数的函数, 即

$$f(t) = C(t) + A(t) \sum_{i=1}^n a_n \sin(k_n \omega(t) + \mu_n) \tag{3}$$

式中, $f(t)$ 为原始信号随时间变化函数; $C(t)$ 、 $A(t)$ 为 $f(t)$ 关于振幅的参变量, 两者皆通过包络线函数 $g(x)$ 求解, 方法如式(4)–(5); $\omega(t)$ 为 $f(t)$ 关于周期的参变量, 可通过对 $f(t)$ 周期或近似周期长度估测得出; a_n 、 k_n 、 μ_n 为函数分解的个数正弦波分量的常数参数, 可通过对 $f(t)$ 进行牛顿-拉夫逊法非线性回归

求解, 如式(6)~(7)。

$$A(t) = \frac{g_+(t) - g_-(t)}{2} \tag{4}$$

$$C(t) = \frac{g_+(t) + g_-(t)}{2} \tag{5}$$

式中, $g_+(t)$ 、 $g_-(t)$ 分别为函数 $f(t)$ 的上包络线和下包络线。

$$E(a_n, k_n, \mu_n) = \sum_{i=1}^m (y_m - f(t_i))^2 \tag{6}$$

$$x_{n+1} = x_n - \mathbf{H}^{-1} \nabla E(x_n) \tag{7}$$

式(6)中 $E(a_n, k_n, \mu_n)$ 为误差函数, 本文采用平方误差和, 式(7)为多元函数 E 的牛顿-拉夫逊法迭代方程, 其中 $x = [a_n, k_n, \mu_n]$ 为参数向量, ∇E 为误差函数 E 的梯度向量, \mathbf{H} 是误差函数 E 的海森矩阵, 牛顿-拉夫逊法通过式(7)迭代更新参数 a_n 、 k_n 、 μ_n , 使 $E(a_n, k_n, \mu_n)$ 最小化, 达到收敛条件, 从而完成 $f(t)$ 非线性回归。

在得到 $f(t)$ 的函数关系式后, 对数据曲线 $f(t)$ 的预报就转化为了对参变量 $C(t)$ 、 $A(t)$ 和 $\omega(t)$ 的预报, 即对包络线 $g(x)$ 和周期序列 $T(t)$ 的预报, 实现简化曲线复杂度、提高预报效率的目的。

改进 LSTM 模型虽然对原始数据进行了预处理, 但由于波浪等信号的分解通常具有保真性, 且非线性回归具有补偿作用, 原则上在预处理中损失的信号特征可以得到还原, 不会影响后续预报精度。

综上所述, 基于改进 LSTM 的极短期预报方法流程可总结如图 3。

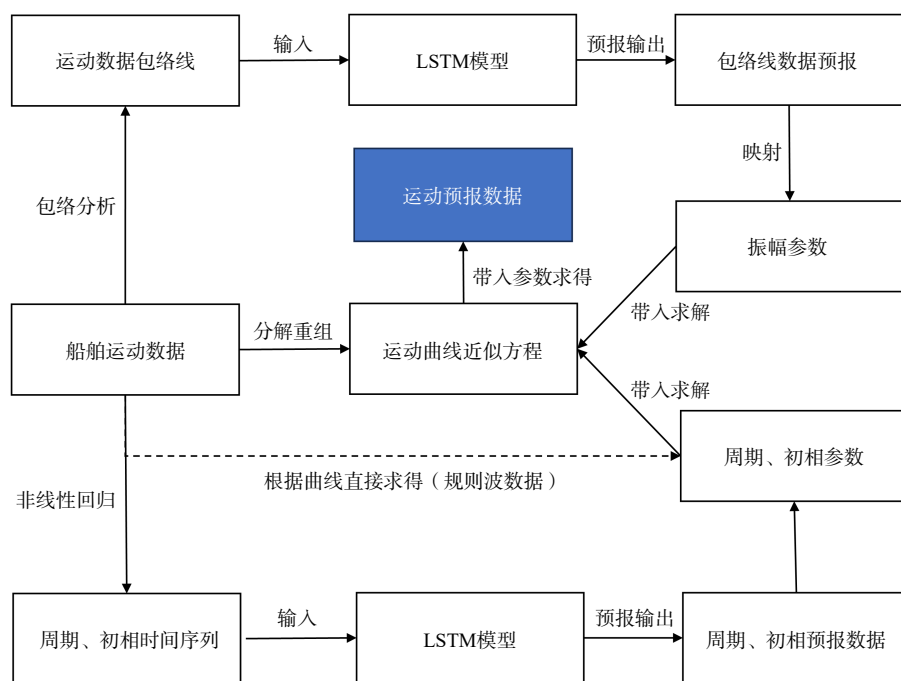


图 3 改进 LSTM 极短期预报方法流程图

Fig.3 Flow chart of the improved LSTM based extreme short-term prediction method

1.3 预测结果评估方法

对于模型整体预测结果的评估, 本文采用均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE), 以及数据落在指定预测区间(prediction interval)的概率(预测率)这三个参数进行综合评估。其中最大绝对误差给出了预测过程中误差的最大值, 均方根误差则体现了整体预测误差情况及数据的稳定程度, 预测率则直观展示了预测精度的高低^[12]。

MAE、RMSE 以及本文设定的数据预测区间的上下限数学表达式为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - l_i)^2} \tag{8}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |l_i - p_i| \tag{9}$$

$$a_{\pm} = l_i \pm \sigma_l \tag{10}$$

式中, p_i 为第 i 个预测数据, l_i 为第 i 个理论数据, a_{\pm} 为预测数据的上下限, σ_l 为真实数据的标准差, N 为数据总量。

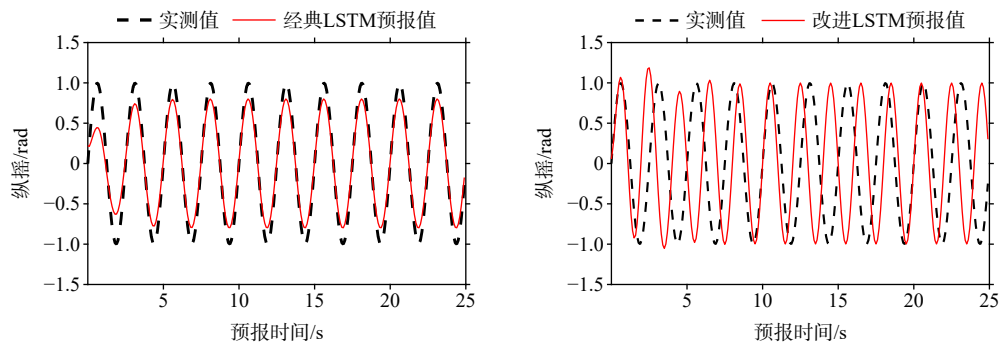
2 结果分析

研究表明, 在理想状态下, 水体波浪通常以正弦波等周期波的形式表现, 船舶运动受此类波浪影响, 其运动数据也通常会表现出周期波或近似周期波的特性^[11]。然而, 实际海况中, 大部分海浪的分布并不具有显著周期性, 规则波或近似规则波极少, 因此船舶运动曲线主要呈现不规则波的特性^[13]。此外很多研究指出船舶横摇等运动数据受到外界因素影响, 往往会在某一时段发生幅值、频率的突变现象, 生成突变波, 导致船舶运动曲线更为复杂^[14]。

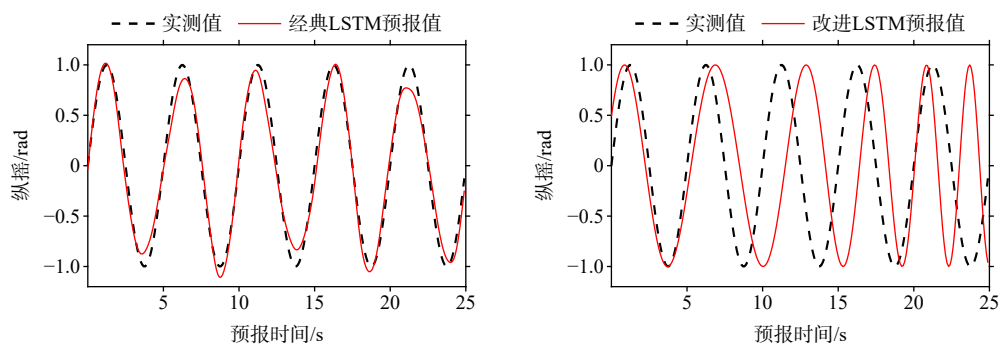
综上所述, 本文将船舶在运动过程中的运动数据曲线分解为四类: 规则波、近似规则波、不规则波、突变波^[15]。为了测试改进的 LSTM 方法对这四种形态的数据曲线的预报效果, 以 0.1 s 为采样时间间隔, 生成 14 组 125 s 模拟波形, 每组包含 1250 个数据点。

2.1 改进 LSTM 预报方法对规则波的预报

生成周期分别为 2.5 s、5 s、12.5 s、25 s 的规则波, 分别使用传统 LSTM 方法和改进的 LSTM 方法对生成的四组不同周期的规则波曲线进行预报, 结果见图 4, 误差分析见图 5。



(a) $T=2.5$ s



(b) $T=5$ s

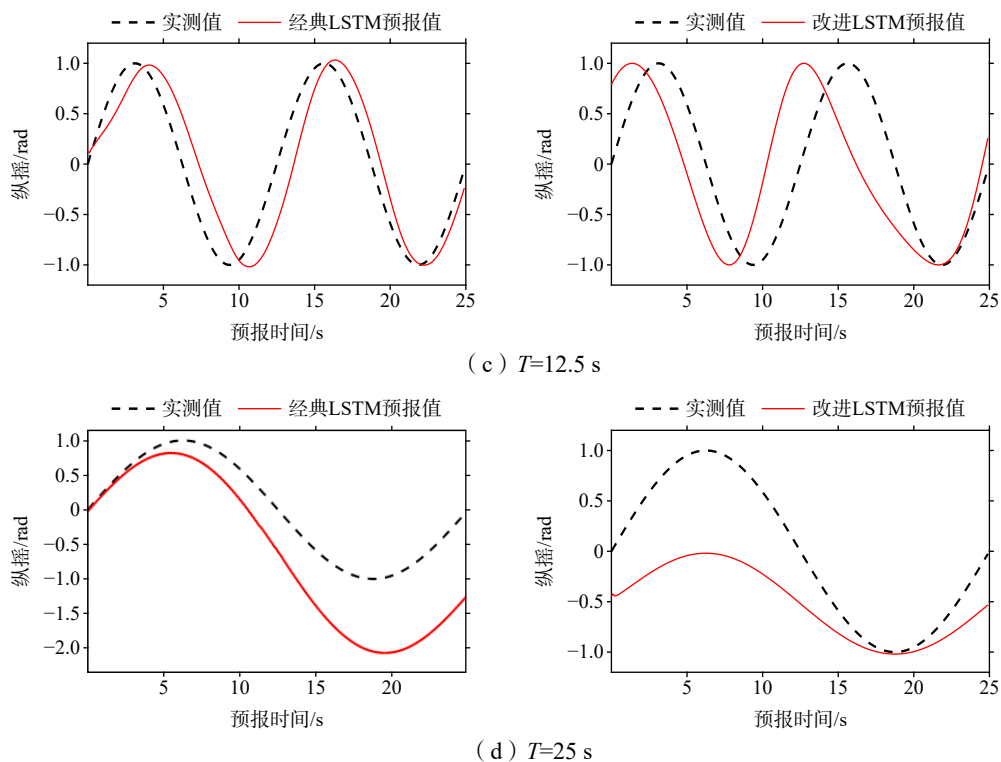


图4 两种 LSTM 预测方法对规则波的预报

Fig.4 Prediction of regular waves by two LSTM prediction methods

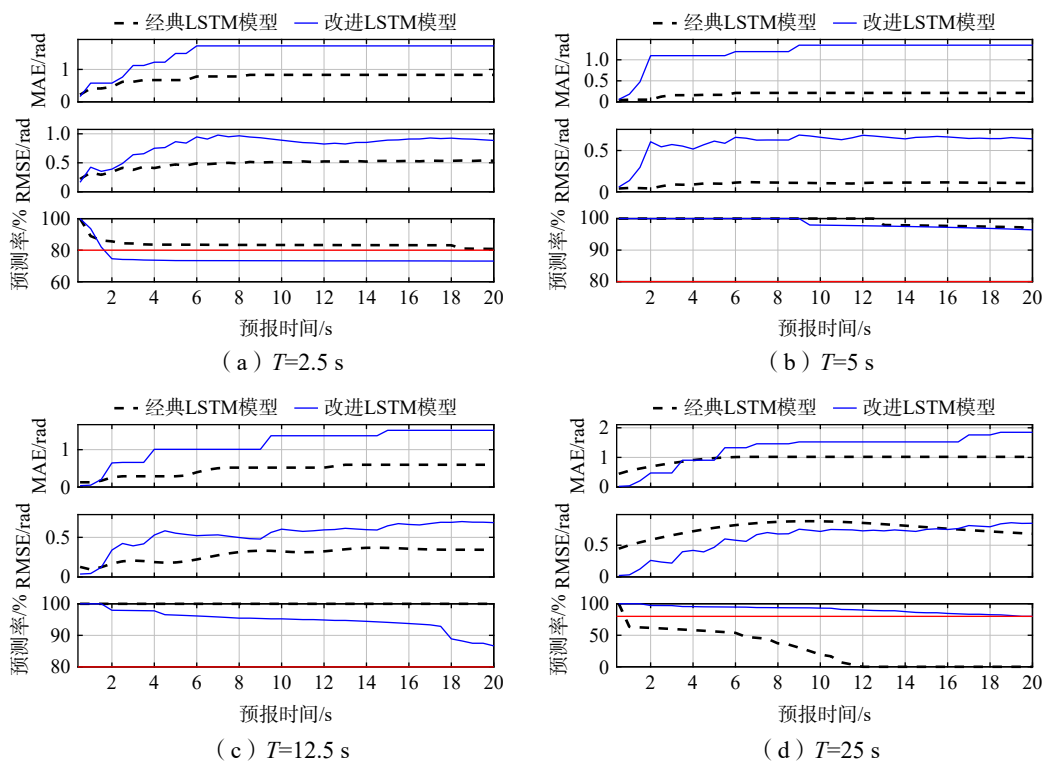


图5 两种 LSTM 预测方法对规则波预报的均方根误差、平均绝对误差和预测率

Fig.5 Root mean square errors, mean absolute errors and prediction rates of two LSTM prediction methods for regular wave prediction

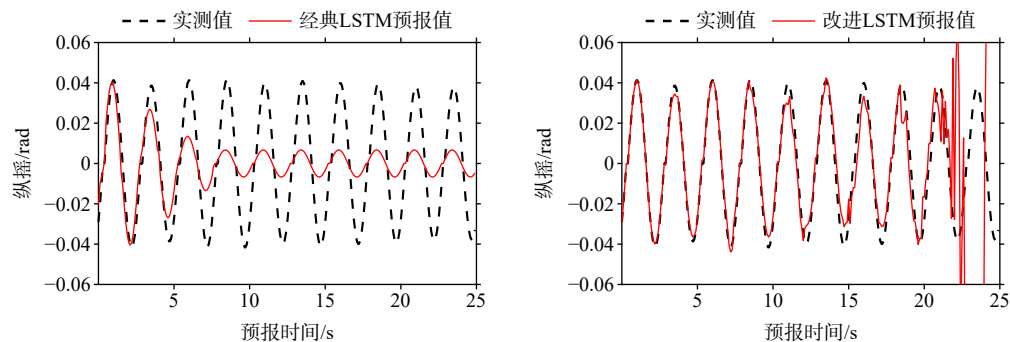
由图 4-5 可知,对于周期不变规则波曲线,当曲线周期较短、包含周期数较多时,传统 LSTM 极短期预报方法的有效预报时长可达 10 s 以上,而改进 LSTM 极短期预报方法的有效预报时长不足 5 s,且传统 LSTM 预报精度明显优于改进 LSTM 预报模型。这是因为传统 LSTM 模型对于简单规则曲线的预报具有天然优势^[16],而改进模型因为多进行了 2 次 LSTM 预报,会导致误差累积叠加,同时由于规则波的振幅不变,其包络线为直线,无法发挥基于包络线预报的优势,这导致改进方法的预报精度反而不如传统模型。另外观察到,规则波周期较短、包含的周期数较多时,传统 LSTM 极短期预报结果更好,这是因为训练集包含的稳定周期越多,LSTM 就越能学习到曲线周期特性。相较之下,LSTM 对周期为 25 s 的规则波的预报结果就较差,因为该段规则波仅包含 8 个周期用于训练,LSTM 没能很好掌握其周期性。

上述现象可从以下三个层面进行解释:首先,从模型特性来看,经典 LSTM 模型在处理具有严格周期性的规则信号时具有天然优势,这得益于其门控机制对时序规律的捕捉能力。而改进模型由于采用了包络线分解与多次 LSTM 预报的架构,在规则波场景下反而会因误差累积效应导致性能下降。其次,就信号特征而言,规则波的恒定振幅使得其包络线退化为直线,导致改进模型中基于包络线预测的优势无法体现。最后,从训练数据角度分析,当规则波周期较短时,单位时长内包含的完整周期数更多,这为 LSTM 模型学习周期特性提供了充足的训练样本。相比之下,对于周期较长(25 s)的规则波,相同时长内仅包含 8 个完整周期,训练数据的不足直接影响了模型对周期性规律的掌握程度,这一现象对经典 LSTM 模型影响更严重,使得经典 LSTM 模型在对 25 s 的长周期规则波进行预报时,预报精度在后期反而不如改进模型,这是深度学习模型性能与训练数据完备性之间的体现。


2.2 改进 LSTM 极短期预报对近似规则波的预报

生成平均周期分别为 2.5 s、5 s、12.5 s、25 s 且周期变化率为 10%、振幅变化率为 5% 的近似规则波,分别使用传统 LSTM 方法和改进的 LSTM 方法对不同平均周期的近似规则波曲线进行预报,结果见图 6,误差分析见图 7。

由图 6 及图 7 可知,当周期不再恒定且曲线振幅发生变化时,传统 LSTM 方法的预报精度显著下



(a) $\bar{T}=2.5$ s



(b) $\bar{T}=5$ s

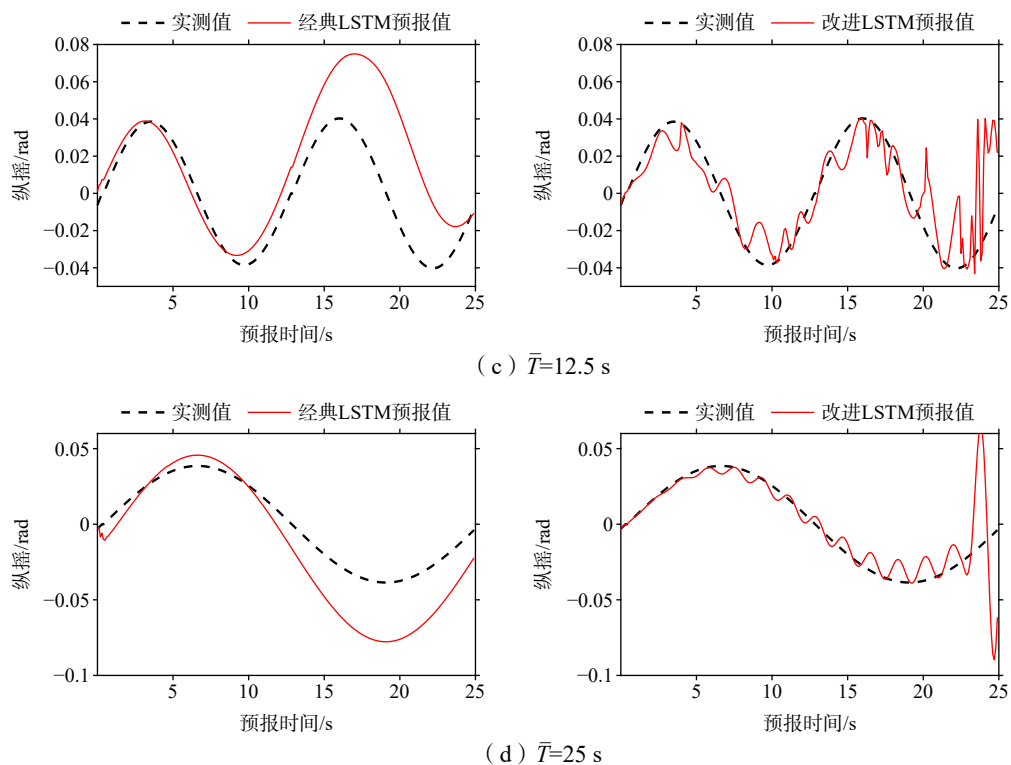


图 6 两种 LSTM 预测方法对近似规则波的预报

Fig.6 Prediction of approximate regular waves by two LSTM prediction methods

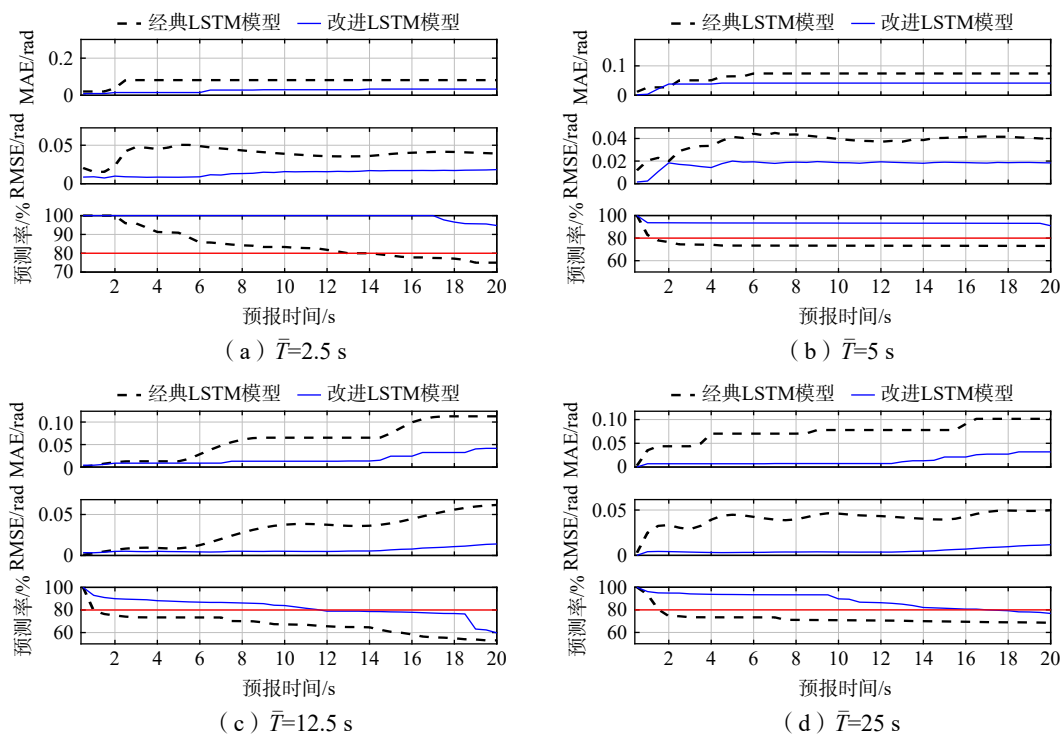


图 7 两种 LSTM 预测方法对近似规则波预报的均方根误差、平均绝对误差和预测率

Fig.7 Root mean square errors, mean absolute errors and prediction rates of two LSTM prediction methods for approximate regular wave prediction

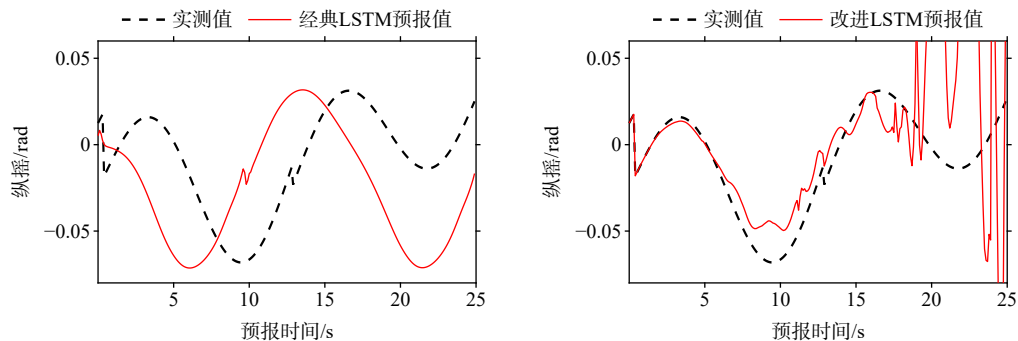
降, 仅能在周期数较少时保持 6~10 s 左右的预报精度, 其中平均周期为 12.5 s 时预报结果最好, 平均周期为 2.5 s、5 s 时的预报精度最差, 这是因为周期振幅的变化会对 LSTM 的周期性训练产生干扰, 导致预报结果的周期和振幅都产生偏差, 曲线包含的周期数越多, 其影响就越大^[17], 如图 6 所示, LSTM 对平均周期为 2.5 s 的近似规则波进行预报时给出了显著偏小的振幅, 导致预报结果不准确, 但由于 2.5 s 的平均周期在 10% 的周期变化率影响下变化范围较小, 因此预报结果的周期与原始数据基本一致, 仍然准确。LSTM 对平均周期为 5 s 的近似规则波的预报则相反, 由于周期变化幅度相对较大, LSTM 预报结果的周期偏小, 导致预报结果不准确。传统 LSTM 对平均周期为 12.5 s 和 25 s 的近似规则波预报也会受到干扰, 但因为曲线本身包含的周期数较少, LSTM 反而没有受到周期、振幅变化的过多影响, 其预报结果与规则波变化不大。

而改进 LSTM 方法对此类曲线的预报结果显著优于经典 LSTM 方法, 能保持约 20 s 左右的最大预报时长。通过改进 LSTM 方法对生成的包络线进行预报可以一定程度掌握原始曲线的振幅变化, 虽然包络线周期性较差、包含周期数较少的特点也会一定程度影响预报精度, 但因为其比原始曲线波动更小, LSTM 预报的误差也更小, 在可接受范围内; 同时, 因为改进 LSTM 模型会对原曲线周期-时间变化函数进行预报, 并能根据曲线周期变化实时调整自身周期, 进一步提高预报精度。

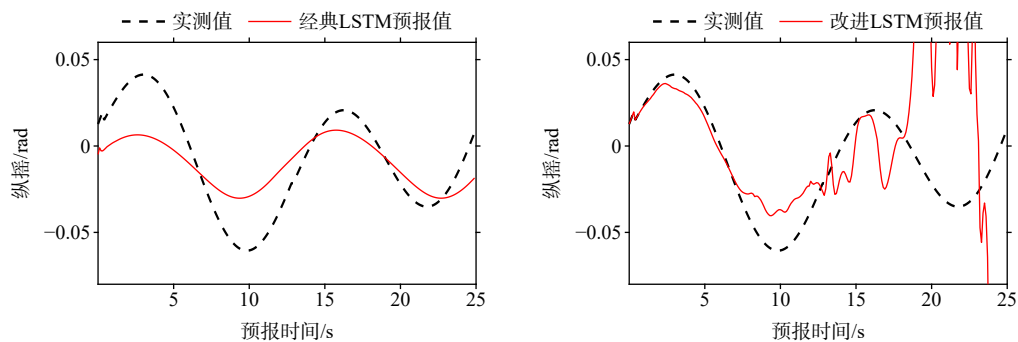
另外值得注意的是, 改进 LSTM 预报模型在 20 s 附近出现了预报数据剧烈波动的情况, 后两条曲线预测率在 20 s 附近下降至 80% 以下, 一方面可能是因为 20 s 的时间节点接近此改进模型的有效记忆深度极限, 成为了该模型的有效预报时限。另一方面, 从数据特征来看, 上述近似规则波在 20 s 内已经历数个近似周期变化, 而其累积的周期、相位误差在此时间节点附近达到临界值。改进模型虽然通过包络线分解缓解了这一问题, 但在处理由多个非线性过程产生的误差共振叠加时, 仍会出现改进 LSTM 模型预测性能的阶跃式下降的问题。此外, LSTM 在对包络线预报过程中存在的过拟合问题也是导致此现象的一大原因, 后续需要通过适当调整 LSTM 隐藏层节点数等方法缓解这一问题。

2.3 改进 LSTM 极短期预报对不规则波的预报

生成周期、振幅随机变化的不规则波, 分别使用传统 LSTM 方法和改进的 LSTM 方法对不同平均周期的不规则波曲线进行预报, 结果见图 8, 误差分析见图 9。



(a) 1号不规则波



(b) 2号不规则波

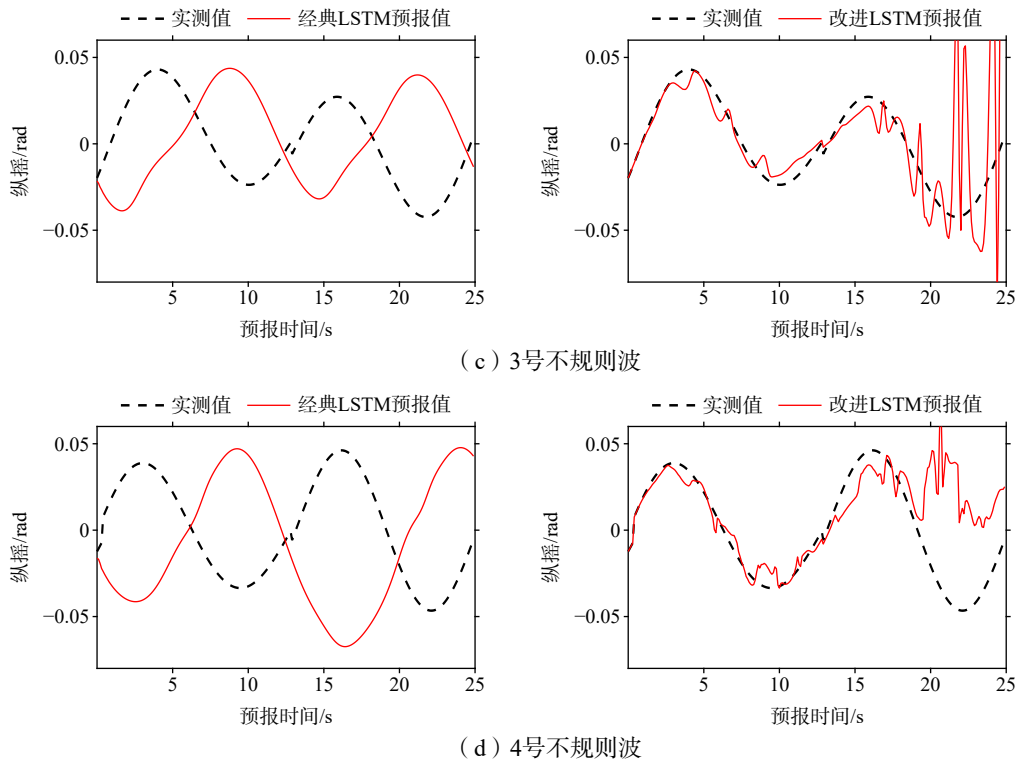


图 8 两种 LSTM 预测方法对不规则波的预报

Fig.8 Prediction of irregular waves by two LSTM prediction methods

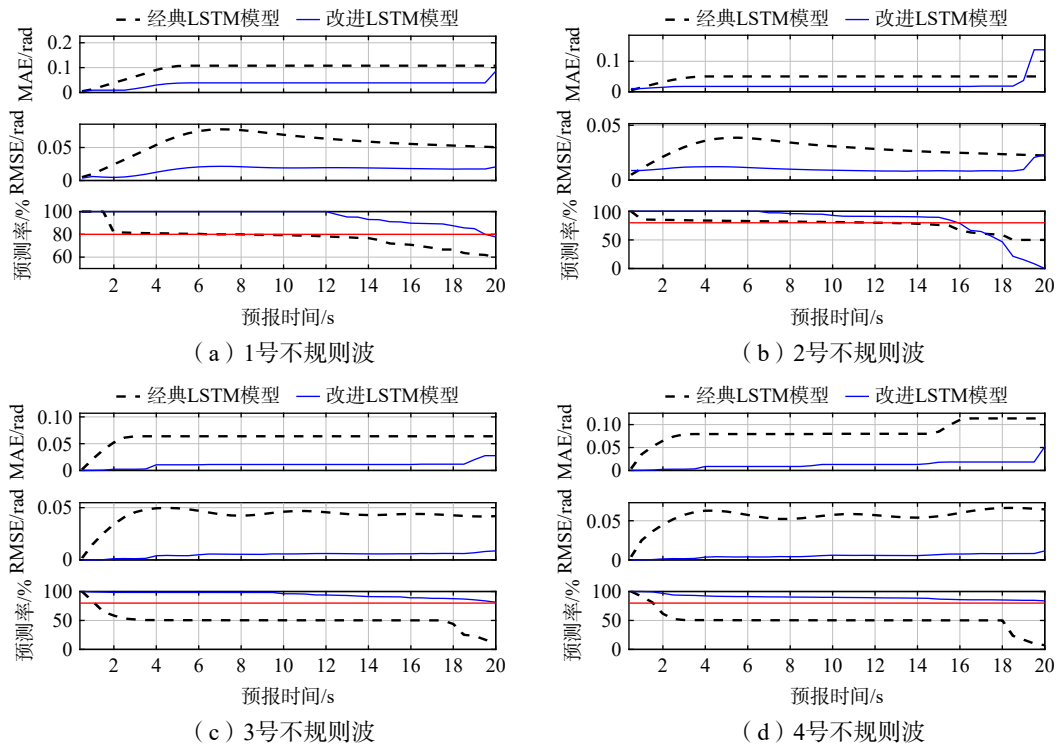


图 9 两种 LSTM 预测方法对不规则波预报的均方根误差、平均绝对误差和预测率

Fig.9 Root mean square errors, mean absolute errors and prediction rates of two LSTM prediction methods for irregular wave prediction

由图 8-9 可知,经典 LSTM 模型因固有的局限性,在不规则波中难以很好地提取周期和振幅的变化特点,从而在波形周期性、幅值准确性等方面均造成较大的误差。而改进的 LSTM 极短期预报模型虽然在不规则波下的预报精度相比近似规则波有一定的降低,但仍然可以保持较长的 18~20 s 的预报时长。在对误差指标进一步的对比分析过程中,发现改进模型在预测率指标上较经典 LSTM 模型提升约 20%~40%,RMSE、MAE 指标则仅为经典模型的 20%,这表明对于潜在的周期非平稳的不规则波浪,改进模型能够根据包络提取和特征分解适应波浪参数的非线性变化,体现出该改进模型对具有随机性和弱周期性的船舶运动信号的适应能力,以及较经典模型更强的鲁棒性。

另外,本文发现改进模型预报数据 20 s 后峰值异常波动的现象未能显著体现在误差曲线上,这可能是由于均方根误差和平均绝对误差具有全局平均特性,其对短期(<20 s)高精度数据的平滑作用掩盖了长期(≥20 s)预报中峰值波动的异常误差,从而产生了此类问题。

2.4 改进 LSTM 极短期预报对突变波的预报

在平均周期为 10 s 的非固定周期信号中,随机截取数段数据,将其依次替换为常数、高频信号(确保一段突变在测试集中,其余在训练集中),生成两种突变波。分别对生成的含突变的信号使用两种方法进行预报,并评估两种方法在突变段(测试集 5 s 至 10 s 段)的预报结果,预报结果见图 10,误差分析见图 11。

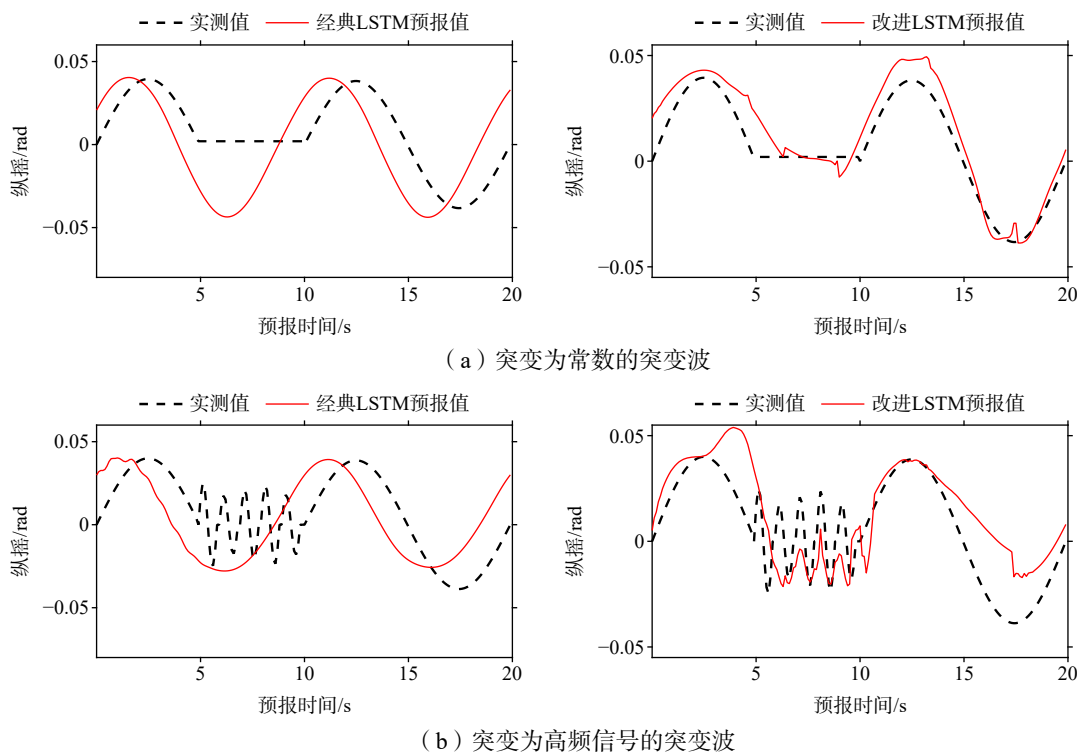


图 10 两种 LSTM 预测方法对突变波的预报

Fig.10 Prediction of abrupt waves by two LSTM prediction methods

由图 10~11 可知,传统 LSTM 模型无法适应任何突变,预报结果在突变段仍然保持突变之前的波形,导致该段数据预报误差较大。改进 LSTM 方法对突变具有一定的适应性,因为包络线会决定预报曲线的上下变化范围,使得预报曲线不会在突变段与原始曲线偏差过大,并在突变结束后调整回原先的波形,最大程度地减少突变造成的干扰和误差。在对两类突变波突变段的预报中,对突变为常数的曲线预报结果更好,这是因为此类突变波突变段是直线,只要预报曲线能在该常数附近波动,就能保证该段的预报精度,而对于突变为高频信号的突变波,因为突变段更为复杂,会显著影响预报精度。

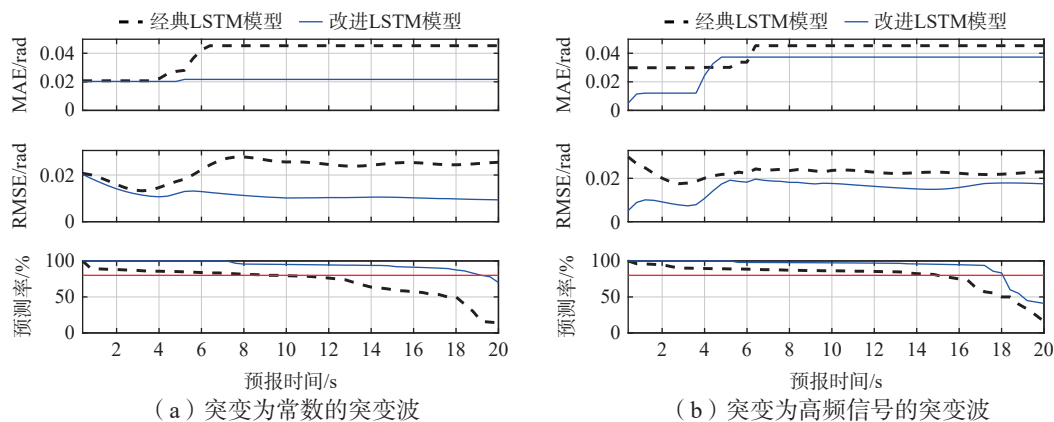


图 11 两种 LSTM 预测方法对突变波突变段 (5~10 s) 预报的均方根误差、平均绝对误差和预测率
 Fig.11 Root mean square errors, mean absolute errors and prediction rates of two LSTM prediction methods for the prediction of the abrupt change section (5~10 s) of the abrupt wave

2.5 改进 LSTM 极短期预报对实体船运动曲线的预报

使用改进 LSTM 极短期预报方法对船模实测运动响应数据进行预报。实测数据见图 12。




图 12 船模实测运动响应原始数据

Fig.12 Original data measured for the motion response of ship model

对降噪后的数据分别使用传统 LSTM 方法、改进 LSTM 方法进行预报, 评估其预报结果, 两种预报方法的结果见图 13。

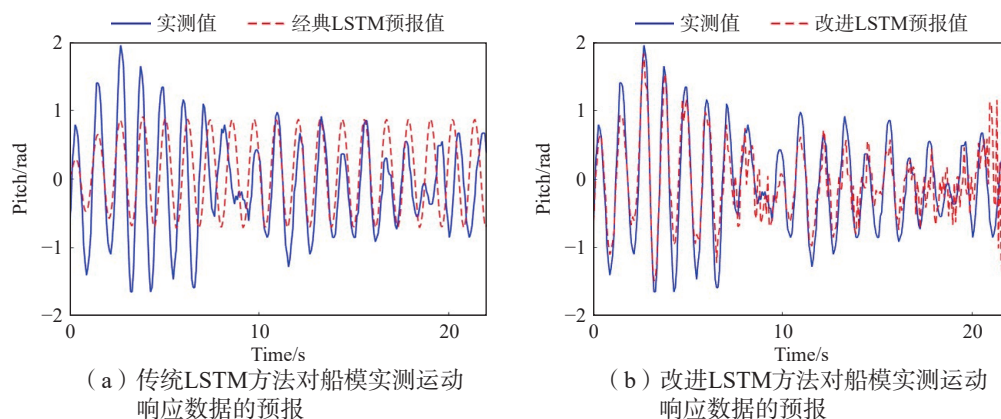


图 13 两种 LSTM 预测方法对船模实测运动响应数据的预报

Fig.13 Prediction of ship model motion response data by two LSTM prediction methods

通过图 13 可以看出在工况确定的情况下, 改进 LSTM 的预报方法优于传统预报方法。改进 LSTM 预报方法能预报 20 s 以上的纵摇数据, 而传统 LSTM 模型因为无法适应实际情况下数据周期、振幅的剧烈变化仅能保持 6 s 左右的预报精度。因此本文提出的改进 LSTM 预报方法具有实用价值。

3 结 论

本文通过将 LSTM 神经网络用于船舶运动极短期预报的方式,构建基于数据驱动的船舶运动极短期预报系统。在此基础上,结合 CFD 仿真数据进行预报实验,设计出一种改进极短期预报方法,最终得到预报精度更高的极短期预报系统。主要结论如下:

(1)对于周期不变的规则波,传统 LSTM 极短期预报方法在曲线周期较短时预报效果优于改进 LSTM,因其对简单规则曲线具有天然优势,能保持 10 s 左右的预报时长;而改进 LSTM 因多次预报导致误差累积,且规则波振幅不变时无法发挥包络线预报优势,预报精度不如传统 LSTM。此外,规则波周期短、周期数多时,传统 LSTM 能更好地学习曲线周期特性,因此,预报结果更好。

(2)当周期不恒定、振幅变化时,传统 LSTM 预报精度显著下降,改进 LSTM 则表现更优,能保持 20 s 左右的预报时长。

(3)对于不规则波,传统 LSTM 预报结果较差,改进 LSTM 虽受影响但仍能保持 18~20 s 的预报时长和一定的预报精度,且对具有周期特征的不规则波预报更具有优势。

(4)传统 LSTM 无法适应任何突变,改进 LSTM 则对突变具有一定适应性,能减少突变造成的干扰和误差。

(5)在对船模实测运动响应数据的预报中,改进 LSTM 预报能达到 20 s 左右的最大预报时长具有实用价值。

参 考 文 献:

- [1] 尚凡成,李传庆,詹可,等.改进 LSTM 神经网络在极短期波浪时序预报中的应用[J].上海交通大学学报,2023,57(6):659-665.
Shang F C, Li C Q, Zhan K, et al. Application of improved LSTM neural network in very short-term wave time series prediction[J]. Journal of Shanghai Jiao Tong University, 2023, 57(6): 659-665. (in Chinese)
- [2] 张怡,孟帅,刘震,等.基于 LSTM 循环神经网络的船舶运动极短期预报[J].船舶工程,2024,46(5):33-40+55.
Zhang Y, Meng S, Liu Z, et al. Very short-term prediction of ship motion based on LSTM recurrent neural network[J]. Ship Engineering, 2024, 46(5): 33-40+55. (in Chinese)
- [3] 赵希人,彭秀艳,沈艳,等.舰船运动极短期建模预报的研究现状[J].船舶工程,2002(3):4-8.
Zhao X R, Peng X Y, Shen Y, et al. Research status of extremely short-term modeling and prediction of ship motion[J]. Ship Engineering, 2002(3): 4-8. (in Chinese)
- [4] 潘文寅,郭孝先,李欣.基于多平台训练的海洋平台极短期运动预报研究[J].海洋工程,2024,42(2):68-79.
Pan W Y, Guo X X, Li X. Extremely short-term motion prediction of offshore platform based on multi-platform training[J]. Ocean Engineering, 2024, 42(2): 68-79. (in Chinese)
- [5] 吴成东,詹可,朱仁传.基于 EMD-LSTM 神经网络模型的气垫船操纵运动预报研究[J].水动力学研究与进展 A 辑,2023,38(5):794-801.
Wu C D, Zhan K, Zhu R Z. Research on maneuvering motion prediction of hovercraft based on EMD-LSTM neural network model[J]. Hydrodynamic Research and Progress A, 2023, 38(5): 794-801. (in Chinese)
- [6] 唐忠.基于高斯过程回归的船舶运动姿态极短期预报方法研究[D].哈尔滨:哈尔滨工程大学,2022.
Tang Z. Research on extremely short-term prediction method of ship motion attitude based on Gaussian process regression[D]. Harbin: Harbin Engineering University, 2022. (in Chinese)
- [7] 张承维,王建华,李志伟.基于注意力机制的双向 LSTM 波浪极短期预报方法[J].船舶力学,2021,25(1):45-53.
Zhang C W, Wang J H, Li Z W. Bidirectional LSTM wave extremely short-term prediction method based on attention mechanism[J]. Journal of Ship Mechanics, 2021, 25(1): 45-53. (in Chinese)
- [8] 李明瑞,赵洪波,陈冠宇. EMD-LSTM 耦合模型在非线性波浪预报中的应用[J].海洋工程,2022,40(2):78-86.

- Li M R, Zhao H B, Chen G Y. Application of EMD-LSTM coupling model in nonlinear wave prediction[J]. Ocean Engineering, 2022, 40(2): 78–86. (in Chinese)
- [9] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735.
- [10] 江龙宇, 华 锋, 江兴杰, 等. 深度学习在波浪预测中应用研究进展[J/OL]. 海洋科学, 2024, 10: 48–61.
Jiang L Y, Hua F, Jiang X J, et al. Advances in the application of deep learning in wave prediction[J/OL]. Marine Science, 2024, 10: 48–61. (in Chinese)
- [11] 文圣常. 海浪原理[M]. 青岛: 山东人民出版社, 1985.
Wen S C. Wave principle[M]. Qingdao: Shandong People's Publishing House, 1985.
- [12] 洪智超, 丁羿杰, 王鸿东, 等. 基于 LSTM 的船舶纵摇极短期预报[J]. 船舶工程, 2024, 46(S1): 589–594.
Hong Z C, Ding Y J, Wang H D, et al. Very short-term prediction of ship pitch based on LSTM[J]. Ship Engineering, 2024, 46(S1): 589–594. (in Chinese)
- [13] 张炳根, 沈毓毅. 关于海浪分布的一种非正态模式[J]. 山东海洋学院学报, 1979, 1(004): 46–50.
Zhang B G, Shen Y Y. A non-normal model of wave distribution[J]. Journal of Shandong Ocean University, 1979, 1(004): 46–50. (in Chinese)
- [14] 王晓玢. 突变控制方法及其在船舶运动中的应用研究[D]. 哈尔滨: 哈尔滨工程大学, 2009.
Wang X Y. Mutation control method and its application in ship motion[D]. Harbin: Harbin Engineering University, 2009. (in Chinese).
- [15] Duan W, Huang L, Han Y, et al. A hybrid AR-EMD-SVR model for the short-term prediction of nonlinear and non-stationary ship motion[J]. Journal of Zhejiang University Science A, 2015, 16(7): 562–576.
- [16] 王国栋, 韩 斌, 孙文赞. 基于 LSTM 的舰船运动姿态短期预测[J]. 舰船科学技术, 2017, 39(13): 69–72.
Wang G D, Han B, Sun W Y. Short-term prediction of ship motion attitude based on LSTM[J]. Ship Science and Technology, 2017, 39(13): 69–72. (in Chinese)
- [17] 吉长东, 吕广涵, 张恒璟, 等. 一种 CORS 站高程序列噪声识别算法[J]. 测绘科学, 2021, 46(3): 8–16.
Ji C D, Lü G H, Zhang H J, et al. A noise identification algorithm for CORS station elevation sequence[J]. Surveying and Mapping Science, 2021, 46(3): 8–16. (in Chinese)