

# 基于拖船作业需求的改进智能算法负荷预测

付文秀, 吴国栋, 宋盛瑶

(上海船舶设备研究所, 上海 200031)

**摘要:** [目的]为提升拖船作业调度效率和能源利用率, [方法]提出一种融合动态数据预处理与在线学习的改进智能负荷预测算法。基于 LSTM 与 Adaboost 混合架构, 通过差异化 LSTM 弱预测器集成与动态权重分配 (误差敏感度惩罚机制), 解决时序特征退化和多模态数据融合问题, 设计在线学习触发机制 (基于预测偏差阈值的自动再训练), 实现模型动态更新; 引入潮汐等环境数据协同优化模块, 提升负荷预测对港口环境的适应性。将该算法与常规 LSTM-Adaboost 算法相对比, 验证该算法的有效性。[结果]结果表明, 经迭代优化之后, 改进算法的均方误差相比常规 LSTM-Adaboost 算法降低 40.8%, 具有较高的预测精度和环境适应性。[结论]研究成果可供港口拖船能耗优化、安全保障和智能化调度参考。

**关键词:** 拖船作业; 港口智能调度; 负荷预测; 在线学习

**中图分类号:** U665.2 **文献标志码:** A **【DOI】** 10.13788/j.cnki.cbge.2026.03.04

## Improved Intelligent Algorithm Load Forecasting Design Based on Tugboat Operation Requirements

FU Wenxiu, WU Guodong, SONG Shengyao

(Shanghai Marine Equipment Research Institute, Shanghai 200031, China)

**Abstract:** [Purpose] In order to improve the efficiency of tugboat operation scheduling and energy utilization, [Method] an improved intelligent load forecasting algorithm integrating dynamic data preprocessing and online learning is proposed. Based on a hybrid LSTM-Adaboost architecture, the algorithm addresses the issues of temporal feature degradation and multimodal data fusion through the integration of differentiated LSTM weak predictors and dynamic weight allocation (error sensitivity penalty mechanism), and designs an online learning trigger mechanism (automatic retraining based on prediction error threshold) to achieve dynamic model updating. Additionally, an environmental data collaborative optimization module, including tidal information, is introduced to enhance the adaptability of load forecasting to port conditions. The algorithm is compared with conventional LSTM-Adaboost to validate its effectiveness. [Result] The results indicate that after iterative optimization, the mean squared error of the improved algorithm is reduced by 40.8% compared to the conventional LSTM-Adaboost algorithm, demonstrating higher prediction accuracy and environmental adaptability. [Conclusion] The research results can provide a reference for tugboat energy optimization, safety management, and intelligent scheduling in ports.

**Key words:** tugboat operation; intelligent port scheduling; load forecasting; online learning

### 0 引言

港口拖船的负荷是指拖船动力系统在特定作业

工况下须输出的机械功率, 其预测核心是未来时段的功率需求时序估计, 主要作用体现在调度优化、

收稿日期: 2025-06-14; 修回日期: 2025-10-01

基金项目: 工信部绿色智能船舶标准化引领工程 (CBG4N21)

作者简介: 付文秀 (1989—), 女, 硕士、高级工程师。研究方向: 船舶电力系统及智能化。

能耗管理、安全合规和智能升级4个方面,即:通过预测高峰负荷,实现错峰调度(如规避台风期作业),降低燃油成本;通过关联负荷强度和油耗,实现节能运行;规避超负荷运行风险,满足港口碳排放监管要求;为自动化调度系统提供决策输入,替代人工经验驱动模式。

港口拖船作业是船舶靠离泊和装卸货的关键环节,其负荷效率(单位时间内有效作业功率与能耗的比值)直接影响港口的吞吐能力。拖船的燃油消耗和机械磨损与其负荷强度直接相关。通过预测负荷分布,优化航行燃油消耗、均衡工作强度并延长设备的使用寿命。现代港口正向自动化、数字化转型,负荷预测已成为智能调度系统的核心输入之一。

拖船作业负荷预测需应对动态港口环境(如温度和潮汐)与多源异构数据(设备状态和船舶参数)的耦合影响。传统经验驱动的调度依赖人工判断,易受主观因素的干扰;负荷预测通过融合历史数据、实时感知信息和机器学习模型,可提供科学的决策依据。SABER等<sup>[1]</sup>揭示了负荷预测模型面临的对抗性攻击风险,强调鲁棒性设计的重要性。AMRAL等<sup>[2]</sup>结合联邦学习解决数据隐私问题,同时提升预

测性能。PAPPAS等<sup>[3]</sup>针对经济调度场景设计专用模型,优化电力系统的运行效率。单一模型存在一定的局限性<sup>[4-8]</sup>,如,长短期记忆(Long Short-Term Memory, LSTM)擅长处理长期依赖性,但对噪声敏感;自适应增强算法(Adaptive Boosting, Adaboost)的鲁棒性较强,但须适配时序任务,须针对拖船作业特性进行改进。

本文融合LSTM时序处理与Adaboost集成优化优势,解决多源异构数据耦合问题。通过差异化LSTM弱预测器集成与动态权重分配(误差敏感度惩罚机制),引入潮汐等环境数据协同优化模块,设计在线学习触发机制(预测偏差触发边界值自动再训练),实现模型动态更新,提升负荷预测模型对港口动态环境的适应性。

## 1 负荷预测算法

负荷预测算法主要包括传统统计方法、机器学习方法、深度学习方法和混合方法等。各负荷预测算法的技术路线及其与拖船场景的适配性对比分别见表1和表2。

表1 负荷预测算法技术路线

Tab. 1 Technical Route of Load Forecasting Algorithm

类型	代表算法	核心原理	拖船场景适用性
传统统计方法	自回归滑动平均模型(Auto-Regressive Integrated Moving Average Model, ARIMA)、指数平滑和回归分析	基于历史数据统计规律构建线性时序模型	难以处理突发天气干扰和多源数据耦合问题
机器学习方法	支持向量机(Support Vector Machine, SVM)、随机森林和极端梯度提升(eXtreme Gradient Boosting, XGBoost)	通过特征工程和非线性模型拟合复杂关系	可处理静态数据,但对时序动态性建模不足
深度学习	LSTM、门控循环单元(Gated Recurrent Unit, GRU)和卷积神经网络(Convolutional Neural Network, CNN)	利用循环/卷积结构捕捉长期依赖和空间特征	适用于动态负荷序列,但须解决噪声敏感性问题
混合方法	LSTM-Adaboost改进算法	LSTM时序建模+Adaboost集成优化+在线学习	兼顾动态环境适应性与多模态数据融合

表2 主流混合预测方法与拖船场景的适配性对比

Tab. 2 Comparison of Adaptability of Mainstream Hybrid Prediction Methods in Tugboat Scenarios

混合算法	技术特点	拖船场景优势	核心局限
LSTM-XGBoost	LSTM提取时序特征→XGBoost多变量决策	可融合潮汐和温度等环境因子	实时性差,难以支持分钟级调度决策
Prophet+ARIMA	Prophet分解趋势/季节项→ARIMA修正残差	自动处理周期性负荷波动	对突发设备故障响应滞后
CNN-LSTM	CNN提取局部空间特征→LSTM建模时序依赖	适用于港口视频监控数据联动	计算资源需求高,边缘设备部署困难
LSTM-Adaboost改进算法	LSTM基模型→Adaboost动态加权集成→在线学习触发更新	误差敏感惩罚机制应对突发干扰,轻量化设计支持船载边缘计算	须定期更新潮汐关联参数

神经网络通过多层非线性变换建模表达复杂的

输入与输出关系,用其对拖船负荷进行预测的优势:

1) 可自动进行特征提取，替代人工构建潮汐/温度特征工程，降低主观偏差。

2) 利用LSTM门控机制（遗忘门、输入门和输出门）选择性记忆长期特征，解决靠泊间隙下的作业序列间断性问题，实现动态适应性。

3) 反向传播自动调整权重，最小化预测误差，实现端到端优化。

港口拖船作业的负荷预测主要面临两大挑战：

1) 动态不确定性（台风和设备故障），可通过Adaboost误差敏感惩罚机制，赋予突发波动更高权重，降低动态环境因素的影响。

2) 多源异构数据融合，可通过LSTM多模态输

入通道设计，并行处理时序负荷、离散操作指令和环境数据，动态适配多元数据融合问题。

利用Adaboost的集成优化能力提升LSTM在时间序列预测中的鲁棒性和准确性，同时结合触发条件，借助在线学习机制实时调整港口拖船负荷预测模型，并进行模型再训练，使其满足拖船作业需求。

## 2 改进智能算法设计

### 2.1 架构设计

改进智能算法采用“三层递进式”混合架构（见图1）设计，步骤包括数据预处理、LSTM模型构建、Adaboost集成、训练、预测和后处理。

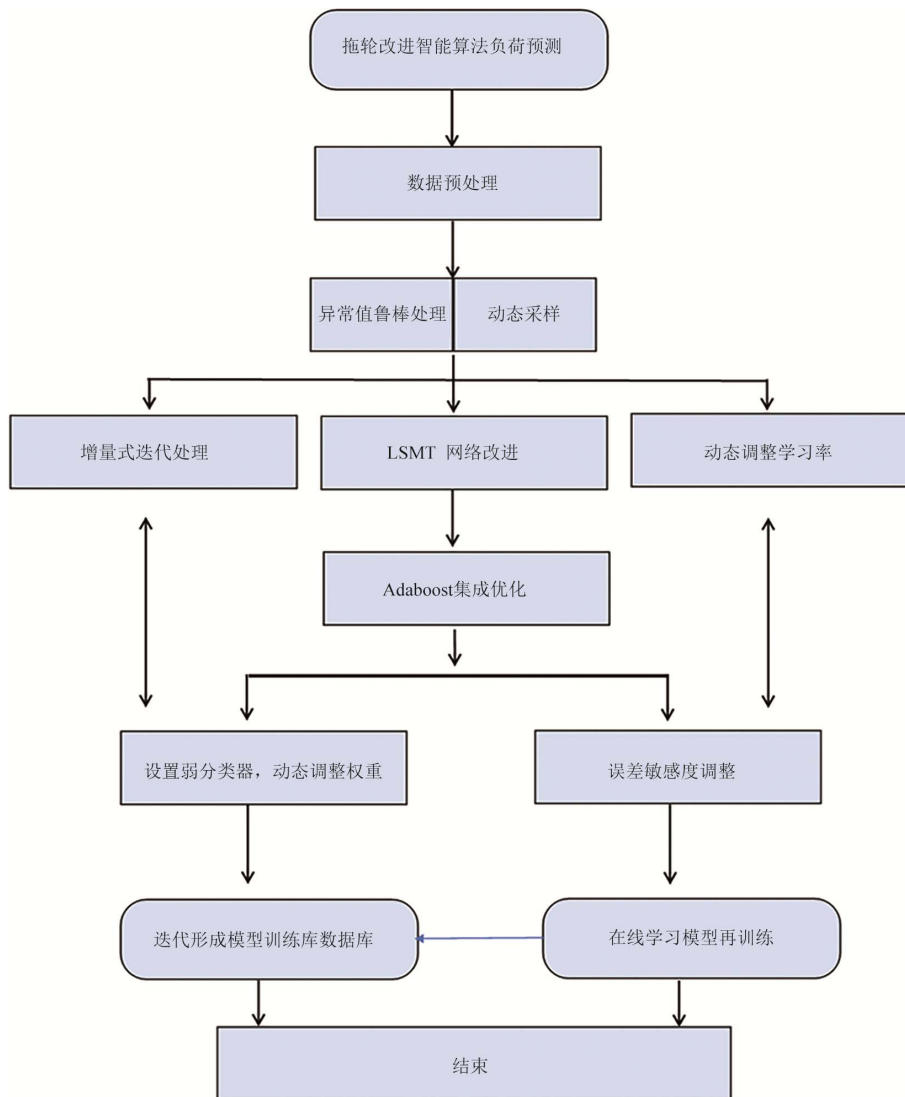


图1 改进智能算法负荷预测架构图

Fig. 1 Improved Intelligent Algorithm Load Forecasting Architecture Diagram

1) 数据预处理层，主要功能是滑动窗口统计、周期性特征提取、动态采样和异常值剔除。处理时间序列数据，可能包括归一化、划分训练集和测试集以及处理缺失值等。

2) 核心模型层，主要功能是LSTM网络改进（增量迭代+动态学习率）和Adaboost集成（10个弱预测器+误差敏感权重）。LSTM部分需设计网络结构，比如层数和隐藏单元数等，通过增量式迭代和动态

调整学习率进行迭代改进; Adaboost集成优化模块进行基模型选择、动态权重分配和误差敏感度调整。

3) 在线优化层, 主要功能是实时监控触发再训练, 融合潮汐数据协同。实时监控触发再训练(预测偏差连续3次大于15%时自动再训练), 融合潮汐数据协同, 在线学习模型再训练, 实现模型寻优。

## 2.2 改进算法设计

考虑拖船作业的特殊性, 提取动态环境因素(潮汐和环境温度)和设备状态, 利用LSTM处理时间序列数据, 利用Adaboost集成多个LSTM模型, 串行训练多个基学习器并计算每个基学习器的权重系数, 同时对各基学习器的预测结果进行线性组合, 提高预测精度和泛化能力, 生成最终的预测结果。

### 2.2.1 数据建模预处理及改进

拖船作业的数据处理和特征选择是关键步骤, 具体见表3, 采用滑动窗口处理时间序列数据。

表3 数据建模预处理

Tab. 3 Data Modeling Preprocessing

数据类型	数据提取	作用
历史作业记录	拖船功率、任务时长	提取基础负荷规律
环境数据	环境温度和潮汐	修正作业难度系数

#### 1) 特征构建

时序特征: 滑动窗口统计(滑动窗口为1, 代表1 h)、周期性特征(由于10 d以内潮汐数据相对固定, 选取每10 d为1个循环模式), 以适应港口调度变化。

#### 2) 异常值鲁棒处理

数据归一化是数据预处理的关键步骤, 其核心目的是消除不同特征之间的量纲差异, 使数据处于统一的数值范围内。为消除量纲差异, 加速训练, 提升模型的性能, 增强模型的可解释性, 使特征重要性分析更直观, 对处理后的训练集数据进行归一化处理

$$ps_{input} = \frac{n_{input} - n_{MIN, input}}{n_{MAX, input} - n_{MIN, input}} \quad (1)$$

式中:  $ps_{input}$ 为归一化后的数据;  $n_{input}$ 为输入数据;  $n_{MAX, input}$ 为输入数据最大值;  $n_{MIN, input}$ 为输入数据最小值。

对应程序实现如下:

```
inputn, inputps = mapminmax(input_train, 0, 1);
[outputn, outputps] = mapminmax(output_train);
inputn_test = mapminmax('apply', input_test, inputps);
```

另外, 为确保数据可靠, 设置自动剔除Not a Number (NaN) 异点数据。动态采样, 自适应数据

刷新, 并动态进入训练迭代。

#### 3) LSTM网络改进策略

增量式迭代, 一定时间步长之后迭代训练, 程序如下:

```
for i = 1:m % 根据循环步长迭代训练
    xx = data(1 + CN * 1440 + w * (i - 1) : w * (i - 1) + s + CN * 1440, :); % 1440表示训练的数据集, CN表示循环次数
    xx = xx(:);
    input_train = [input_train, xx];
end
```

#### 4) 动态调整学习率

每经过一定时期, 学习率就会乘以一个系数。梯度阈值设置为1。指定初始学习率为0.01, 经过125轮训练之后, 通过乘以因子0.2来降低学习率, 增强长期依赖性建模能力。

### 2.2.2 Adaboost集成优化模块

#### 1) 基模型选择

首先, 构建10个差异化LSTM弱预测器(差异来源于初始化权重和隐藏层节点数); 其次, 采用Adaboost算法将多个弱预测器集成为一个强预测器; 最后, 通过强预测器对弱预测器的预测结果进行加权, 得到最终的结果。

#### 2) 误差敏感度调整

对突发负荷波动的预测误差赋予更高的惩罚权重, 程序如下:

```
for j = 1:nn
    if abs(error(i, j)) > 0.2 & abs(error(i, j)) < 0.8 % 较大误差
        weight(i) = weight(i) + D(i, j);
        D(i + 1, j) = D(i, j) * 1.1;
    elseif abs(error(i, j)) > 0.8 % 异常误差检测
        weight(i) = weight(i) + D(i, j);
        D(i + 1, j) = D(i, j) * 2; % 异常误差赋予更高惩罚权重
    else
        D(i + 1, j) = D(i, j);
    end
end
```

上述算法对突发波动赋予更高的权重(误差大于0.8时权重乘以2), 实现误差敏感惩罚。

#### 3) 损失函数

针对回归任务, 损失函数以均方误差MSE为主损失, 以平均绝对百分比误差MAPE为辅助指标。

(1) 均方根误差MSE是预测值与真实值之间误差平方的平均, 计算公式为

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

(2) MAPE主要反映预测的相对误差程度, 通常应用于经济和预测领域, 计算公式为

$$M_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (3)$$

式 (2) 和式 (3) 中:  $n$  为样本数量;  $\hat{y}_i$  为第  $i$  个样本的预测值;  $y_i$  为第  $i$  个样本的真实值。

4) 在线学习模型再训练

实时监控预测偏差, 设置当预测偏差连续3次大于15%时, 触发模型再训练。

2.2.3 多任务协同优化

融合潮汐预报提升负载预测的准确性。提取的当地潮汐数据见图2。当预测数据周期较短时, 不将其纳入模型训练; 当预测数据周期达到月度或季度时, 须考虑潮汐带来的影响。



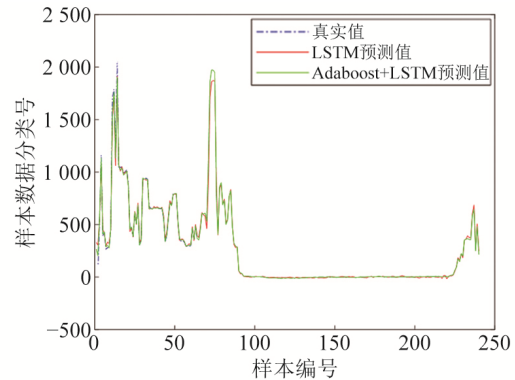


图2 厦门港口潮汐图  
Fig. 2 Chart of Xiamen Port



(a) 预测误差



(b) 样本对应的真实值和预测值

图3 优化前基于 Adaboost+LSTM 和 LSMT 算法的预测数据对比

Fig. 3 Comparison Results of Prediction Data Based on Adaboost+LSTM and LSMT Algorithms Before Optimization

3.2 动态预测特征量 (多元数据融合)

改变预测考虑的数据观测结果, 表4为基于多元数据融合的动态预测数据观测结果。由表4可知, 当

表4 基于多元数据融合的动态预测数据观测结果

Tab. 4 Dynamic Prediction of Data Observation Results Based on Multivariate Data Fusion

模型数据	负载功率/kW	温度/°C	潮汐/m
LSTM 的均方误差 MSE	375.163 5	340.322 9	874.381 5
改进智能算法 LSTM+Adaboost 的均方误差 MSE	400.687 8	137.719 8	780.977 1

3.3 加入迭代优化后预测结果对比

为取得最优预测结果, 一定时间步长之后, 分别基于Adaboost+LSTM算法和LSTM算法进行迭代训练, 由于数据量限制, 设置迭代次数为9次。通过

3 模型验证

通过将历史数据回测与实时测试相结合, 同时采用实际作业数据进行对比, 调整模型参数, 确保预测结果符合实际作业场景的需求。选取 $9 \times 1\ 200$ 个样本 (这里的9是迭代次数, 由于数据不能超过数组最大范围14 339, 因此只能迭代9次) 作为训练集进行迭代寻优, 每个样本的组成为当天24 h的全部数据, 因此训练集的输入数据大小为 $1\ 200 \times 24N$ , 其中: 24为24 h;  $N$ 为特征数, 包含潮汐数据、负荷数据和温度数据等, 根据需要对比分析调整特征量。训练集的输出数据大小为 $1\ 200 \times 1$ , 其中1代表未来 1 h 的负荷值。选取 $9 \times 240$ 个样本 (这里的9同样表示迭代次数) 作为测试集。

3.1 改进前基本初始优化前后对比结果

采用训练后的模型进行计算之后得出预测数据 test\_simu0, 将其与实际数据 output\_test 相对比, 得出均方误差 mse0。

图3为优化前基于Adaboost+LSTM和LSMT算法的预测数据对比。LSMT预测结果mse0= $3.295\ 6 \times 10^3$ , Adaboost+LSTM预测结果MSE= $1.350\ 6 \times 10^3$ , 预测误差下降。

考虑温度的动态影响时, 预测数据相比单一功率历史数据库预测误差下降, 但因潮汐数据在短时间内具有固定性, 对预测结果存在干扰影响, 误差略大。

迭代2 400个数据样本, 形成样本 $x$ 、真实值 $y_1$ 、LSTM的预测值 $y_2$ 、Adaboost+LSTM的预测值 $y_3$ 、LSTM的预测误差MSE值 $y_4$ 、Adaboost+LSTM的预测误差MSE值 $y_5$ 、LSTM的预测绝对百分比误差 (MAPE)

值 $y_6$ 和Adaboost+LSTM的预测绝对百分比误差(MAPE)值 $y_7$ 的预测数据及对比曲线, 见图4~图6。

1) 图4为Adaboost+LSTM的预测误差MSE值 $y_5$ 相对于样本 $x$ 的预测结果以及LSTM的预测误差 $M_{MSE}$ 值 $y_4$ 相对于样本 $x$ 的预测结果。通过叠加对比可看出, 采用本文所述基于多元数据融合的改进策略之后, Adaboost+LSTM的预测效果在整个预测期间内均优于LSTM, 个别数据范围的预测存在劣势。

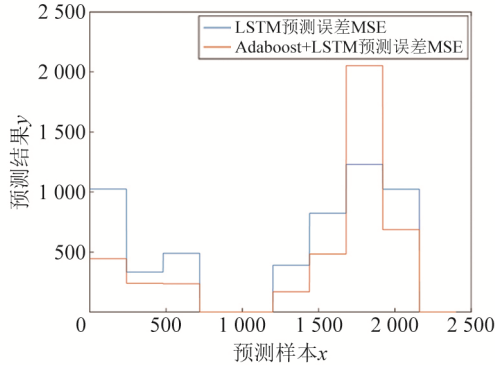


图4 Adaboost+LSTM的预测误差MSE值

Fig. 4 Adaboost+LSTM Prediction Error MSE Value

2) 图5为Adaboost+LSTM的预测误差MSE值 $y_5$ 、LSTM的预测误差MSE值 $y_4$ 、Adaboost+LSTM的预测值 $y_3$ 、LSTM的预测值 $y_2$ 和真实值 $y_1$ 相对于样本 $x$ 的预测结果。

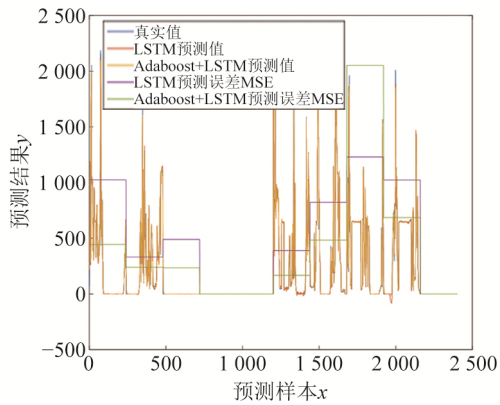


图5 预测误差MSE值-预测值-真实值-样本

Fig. 5 Prediction Error MSE Value-Prediction Value-True Value-Sample

3) 图6为Adaboost+LSTM的预测绝对百分比误差(MAPE)值 $y_7$ 和LSTM的预测绝对百分比误差(MAPE)值 $y_6$ 相对于样本 $x$ 的预测结果。通过叠加对比可进一步看出, 采用本文所述基于多元数据融合的改进策略之后, 在整个预测区间内, 改进的Adaboost+LSTM的预测绝对百分比误差都较低, 预测精度较高。

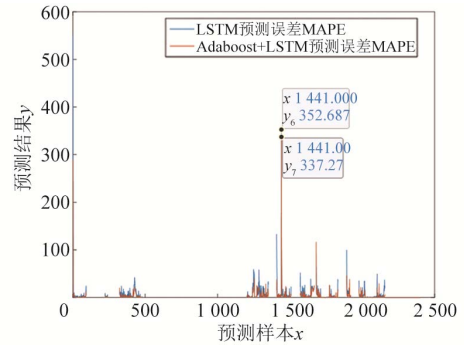


图6 预测绝对百分比误差(MAPE)值-样本

Fig. 6 Prediction Absolute Percentage Error (MAPE) Value-Sample

从图4~图6中可知, 总体上改进的Adaboost+LSTM的预测效果优于LSTM, 预测误差MSE值和预测绝对百分比误差(MAPE)值均较好, 但个别数据范围的预测存在劣势。

### 3.4 加入在线学习后改进算法预测结果对比

对迭代优化后的数据进行在线学习处理, 实时监控预测偏差, 设置当预测偏差连续3次大于15%时触发模型再训练, 进行优化增强, 结果见图7~图10。

1) 图7为加入在线学习之后, 改进的Adaboost+LSTM的预测误差MSE值 $y_5$ 相对于样本 $x$ 的预测结果以及LSTM的预测误差MSE值 $y_4$ 相对于样本 $x$ 的预测结果。对比改进前的数据曲线(见图4)可看出, 采用本文所述基于在线学习和多元数据融合的改进策略之后, 改进的Adaboost+LSTM的预测效果在整个预测期间内优于LSTM, 个别预测区间略低于LSTM, 整体预测误差低于800。

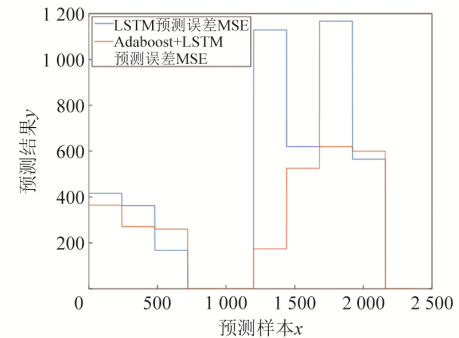


图7 预测误差MSE值-预测值-真实值-样本

Fig. 7 Prediction Error MSE Value- Prediction Value-True Value-Sample

2) 图8为加入在线学习之后, 改进Adaboost+LSTM的预测误差MSE值 $y_5$ 、LSTM的预测误差MSE值 $y_4$ 、Adaboost+LSTM的预测值 $y_3$ 、LSTM的预测值 $y_2$ 和真实值 $y_1$ 相对于样本 $x$ 的预测结果。对比改进前的数据曲线(见图5)可看出, 采用本文所述基于在线学习和多元数据融合的改进策略之后,

预测值紧密跟随实时值，动态响应效果也较好。




图 8 预测误差 MSE 值-预测值-真实值-样本

Fig. 8 Prediction Error MSE Value-Prediction Value-True Value-Sample

3) 图9和图10均为加入在线学习之后，改进的Adaboost+LSTM的预测绝对百分比误差（MAPE）值 $y_7$ 、LSTM的预测绝对百分比误差（MAPE）值 $y_6$ 相对于样本 $x$ 的预测结果。对比改进前的数据曲线（见图6）可看出，采用本文所述基于在线学习和多元数据融合的改进策略之后，在整个预测区间内，改进的Adaboost+LSTM的预测绝对百分比误差均较小，MAPE值最大约为130.165。

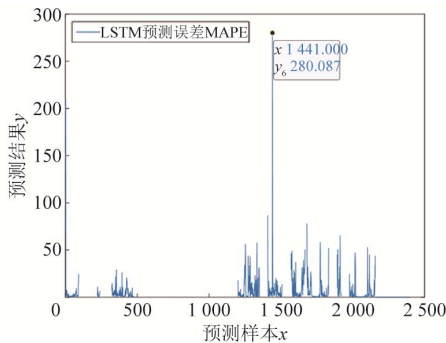


图 9 预测绝对百分比误差（MAPE）值-样本

Fig. 9 Prediction Absolute Percentage Error (MAPE) Value-Sample

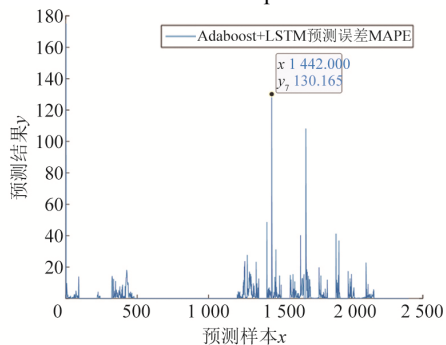


图 10 预测绝对百分比误差（MAPE）值-样本

Fig. 10 Prediction Absolute Percentage Error (MAPE) Value-Sample

由上述分析可知，改进后算法的预测效果相比原算法有明显提升，能鲁棒优化个别奇异点，整个预测范围内的预测误差MSE值由最初的约 $1.3506 \times 10^3$ （LSMT的预测误差为 $3.2956 \times 10^3$ ）降至800以下，降低约40.8%，绝对百分比误差（MAPE）值均在150以下，优化效果显著。

#### 4 结论

本文所述基于在线学习和多元数据融合的改进LSTM-Adaboost算法通过集成学习和在线更新，能有效解决拖船负荷预测中的动态不确定性和数据异构难题，显著提升拖船负荷预测的鲁棒性和实用性，为港口智能化升级提供关键技术支撑，并为负荷调度、能耗优化和节能减排提供强有力依据。

#### 参考文献：

- [1] SABER A Y, ALAM A K M R. Short Term Load Forecasting Using Multiple Linear Regression for Big Data[C]//IEEE Symposium Series on Computational Intelligence. 2017.
- [2] AMRAL N, OZVEREN C S, KING D. Short Term Load Forecasting Using Multiple Linear Regression[J]. International Universities Power Engineering Conference, 2007(42): 1192-1198.
- [3] PAPPAS S S, EKONOMOU L, MOUSSAS V C, et al. Adaptive Load Forecasting of the Hellenic Electric Grid[J]. Journal of Zhejiang University Science A, 2008(9): 1724-1730.
- [4] 杜伟, 王圣, 李健, 等. 基于 CNN-LSTM-AM 模型的储能锂离子电池荷电状态预测[J]. 电工技术学报, 2025, 40(9): 2982-2993.  
DU W, WANG S, LI J, et al. State of Charge Prediction of Energy Storage Lithium Ion Batteries Based on CNN-LSTM-AM Model[J]. Journal of Electrical Engineering, 2025, 40(9): 2982-2993.
- [5] 刘萍, 李泽文, 蔡雨思, 等. 基于等效电路模型和数据驱动模型融合的 SOC 和 SOH 联合估计方法[J]. 电工技术学报, 2024, 39(10): 3232-3243.  
LIU P, LI Z W, CAI Y S, et al. A Joint Estimation Method for SOC and SOH Based on the Fusion of Equivalent Circuit Model and Data-Driven Model[J]. Journal of Electrical Engineering, 2024, 39 (10): 3232-3243.

(下转第 49 页)