

•海洋资源可持续开发与利用•

DOI:10.12454/j.jsuese.202500084



本刊网刊

## 基于注意力机制的 LSTM 多因素滨海航道水深预测及应用研究

凌千展<sup>1,2</sup>, 韩玉<sup>1</sup>, 解威威<sup>1,2\*</sup>, 唐睿楷<sup>1,2</sup>, 胡家锴<sup>1</sup>, 梁光越<sup>1</sup>, 曹璐<sup>1</sup>, 梁铭<sup>1</sup>, 刘祥<sup>1</sup>

(1. 广西路桥工程集团有限公司, 广西南宁 530200; 2. 广西大学土木建筑工程学院, 广西南宁 530004)

**摘要:**为提高平陆运河航道施工运输的安全性、效率与精确性,本文提出一种基于注意力机制的长短期记忆网络(LSTM)多因素滨海航道水深预测模型,并将其集成于航道运输辅助决策平台中。首先,结合上游流量、日降雨量、潮流流速和潮汐水位等关键水文因子,构建基于 LSTM 的滨海航道水深预测模型。然后,引入注意力机制优化模型架构,提高模型在复杂水文环境下超长龄期水深预测的精度和稳定性。在此基础上,将模型集成至航道运输辅助决策平台中,实现水深预测及动态修正、通航窗口期评估等多模块协同工作。最后,通过与现有模型和实测数据的对比分析,验证模型的有效性。分析结果表明:相较于传统 LSTM 模型,基于注意力机制的 LSTM 模型在枯水期和丰水期水文地质环境条件下水深预测平均绝对误差(MAE)分别降低了 64.68% 和 72.36%, 决定系数  $R^2$  分别提升了 2.18% 和 5.60%; 与单一特征向量相比,采用日降雨量、潮流流速和潮汐水位 3 特征向量组合模型, MAE 值不超过 0.15 m,  $R^2$  不低于 0.99, 显著提升模型对滨海航道复杂水文环境下水深预测的精度与稳定性。本文研究成果为提升航道运输智能化和数字化管理水平提供可靠的技术支撑。

**关键词:**平陆运河; 航道施工运输; 航道水深预测; 注意力机制; LSTM 模型; 航道运输辅助决策平台

**中图分类号:** U615.1; U445.4

**文献标志码:** A

**文章编号:** 2096-3246(2026)01-0266-10

随着平陆运河跨线工程建设的持续推进,水上运输的安全性与效率已成为制约施工进度的关键因素之一<sup>[1-2]</sup>。然而,现有航道尚未完成挖深改造,难以满足大型船舶通航需求<sup>[3]</sup>。此外,受多种复杂因素影响<sup>[4-6]</sup>,该区域水深变化频繁,对通航窗口的精准预测提出了更高要求。因此,构建融合多源信息的水深预测模型具有重要意义。

目前,国内外学者在航道水深预测领域进行了广泛研究,并取得了一定进展。现有研究主要分为两大类模型:一类是基于物理机制的水动力学模型<sup>[7]</sup>;另一类是基于数据驱动的机器学习模型<sup>[8]</sup>。Chen 等<sup>[9]</sup>基于水动力学原理,提出了一种结合卡尔曼滤波的水动力学模型,但该模型对多因素耦合下的非线性变化预测较差。Almikael 等<sup>[10]</sup>基于递归神经网络(RNN)提出了一种用于洪水预测的模型,但该模型更多适用洪水、降雨等突发性短序列数据预测,对长序列数据的建模

能力有限。在此基础上, Ma 等<sup>[11]</sup>基于长短期记忆网络(LSTM)构建了向家坝水电站下游水位预测模型。LSTM 解决了 RNN 在处理长时间序列时的梯度消失问题。Zhang<sup>[12]</sup>和 Sun<sup>[13]</sup>等结合 LSTM 捕捉多个水位站和降雨信息特征用于地下水水位预测领域,取得了良好效果。吕海峰等<sup>[14]</sup>提出了一种基于拼接长短期记忆网络(splice-LSTM)的多因素水位预测模型,解决了传统单因素预测模型无法有效考虑上游支流流量等多因素的局限性。上述 LSTM 模型主要存在以下不足:首先,模型均忽略了潮流流速和潮流水位等因素的影响,不适用于滨海区域航道的水深预测;其次,传统 LSTM 模型更多适用于影响因素较少且规律性明显的水位变化预测,在处理多变量、周期性不强的滨海区域复杂水文地质环境时,难以捕捉关键信息特征。因此,有必要进一步建立复杂水文条件下航道水深高精度预测模型。

收稿日期:2025-02-14 修回日期:2025-06-11 网络出版日期:2025-06-13

基金项目:广西重点研发计划(桂科 AB25069194);广西科技重大专项(桂科 AA23062022);国家自然科学基金项目(51738004);中央引导地方科技发展专项(桂科 ZY20221229)

作者简介:凌千展(1994—),男,工程师,硕士。研究方向:大跨桥梁施工工期监测与控制技术。E-mail:511794547@qq.com

\*通信作者:解威威,正高级工程师,E-mail:214395494@qq.com

鉴于此,本文提出了一种基于注意力机制的LSTM多因素滨海航道水深预测模型,并应用于航道运输辅助决策系统。首先,选取上游流量、日降雨量、潮流流速和潮汐水位等关键水文参数作为特征变量,构建基于LSTM的滨海航道水深预测模型。其次,引入注意力机制优化模型结构,提高模型在复杂水文环境下超长龄期水深预测的精度和稳定性。在此基础上,将该模型集成至航道智能辅助系统中,结合工程案例,验证其在实际应用中的可靠性与实用性。

## 1 水文数据获取及预处理

### 1.1 数据来源及运河概况

平陆运河位于广西壮族自治区境内,是中华人民共和国成立以来建设的第一条通江达海的运河工程,全长约134.2 km<sup>[15]</sup>。但在部分航道尚未进行扩宽和挖深之前,航道水深较浅,无法满足大型船舶通航的要求,特别是在滨海浅滩水域,航道运输受限尤为显著。图1为低潮时航道浅水区。



图1 低潮时航道浅水区

Fig. 1 Shallow water area of the waterway during low tide

相比于陆运,水运具有大规模、低成本、高效率等显著优势,尤其在运输大型构件时更具适用性。平陆运河跨线桥梁工程地处滨海浅滩水域,航段全长15 km。由于该航道水深较浅,且受潮汐作用影响显著,水深动态波动剧烈,因此需充分利用涨潮时海水倒灌、上游泄洪或雨季降雨所带来的水深提升,以确保运输窗口期达到必要的水深条件。如何精准预测并把握航道运输窗口期,成为确保运输和作业顺利实施的关键问题,如图2所示。



图2 大型施工构件水上运输

Fig. 2 Waterborne transportation of large-scale construction components

为实现平陆运河航道运输的水深预测进而确定未来运输窗口期,进行如下工作。首先,在整个航道范围内布设3个监测点,分别位于金海湾大桥、钢构厂和钦江大桥。航道监测点示意图如图3所示。监测频率为1次/h,采集内容包括测点的水深(单位:m)和流速(单位:m/s)。自监测点于2023年建成投入运行以来,已累计采集超过10余万组监测数据。其次,收集入海口处龙门港观测站(国家海洋信息中心设立的潮汐观测点)的站内资料,包括潮高和潮差(单位:m),以及3个具备历史气象记录的观测站(灵山站、浦北站和钦州站)的站内资料,包括日降雨量(单位:mm)和水流量(单位:m<sup>3</sup>/s)。在对上述资料进行筛选后,选择时间跨度为2023年1月1日—2024年12月31日的数据进行分析。其中,待测点水深和流速采样间隔为1 h,共计105 120条。潮汐水位的数据采样间隔为1 h,共计35 040条;日降雨量和上游流量的数据采样间隔为1 d,共计1 460条。




图3 航道水位监测点

Fig. 3 Water level monitoring stations along the navigation channel

### 1.2 数据预处理

深度学习模型的训练效果依赖于数据的质量,但监测过程中因设备故障或通信中断等问题,原始数据常存在缺失值和异常值。对此,需对原始水文数据进行预处理。

1) 缺失数据填补:本文采用 Stacked-LSTM 算法<sup>[16]</sup>进行缺失数据填补,该算法堆叠多个 LSTM 层,并学习所收集数据的序列模式和特征。其中,滑窗窗口长度经过试算后确定为20,训练抓取样本数的批量大小(batch size)取50,迭代次数(epoch)取100。

2) 异常值处理:通过3倍标准差准则<sup>[17]</sup>计算原始水文数据的标准差<sup>[18]</sup>,进而剔除均值附近3倍标准差区间以外的异常值。

3) 归一化处理:考虑到水深和潮汐水位的单位为m,流速的单位为m/s,日降雨量单位为mm,各变量的量纲存在差异,需对数据进行归一化处理(归一化后的数据集均处于0~1区间范围内):

$$f(x_t) = \frac{x_t - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, $f(x_t)$ 为 $t$ 时刻的数据归一化值, $x_t$ 为 $t$ 时刻的输

入特征,  $x_{\min}$  和  $x_{\max}$  分别为数据集中的最小值和最大值。

## 2 航道水深预测多因素模型

### 2.1 模型框架

本文提出的基于注意力机制的 LSTM 航道水深预测模型框架包括数据重构层、特征融合模块和输出层<sup>[19-22]</sup>。首先,通过数据重构层对多源时序数据(潮汐水位、流速、日降雨量和上游流量)进行归一化和高维表示;然后,特征融合模块利用多头注意力机制提取全局时序特征,解码器结合掩盖多头注意力和前馈网络生成高精度预测结果;最后,通过输出层输出下一时刻的航道水深预测值。在长时间序列预测中,模型性能受特征选择和权重分配的影响。为提高长时间序列预测精度,本文通过引入注意力机制自适应地调整特征权重,忽略不相关的特征,提高模型预测精度。图 4 为基于注意力机制的 LSTM 模型基本流程。

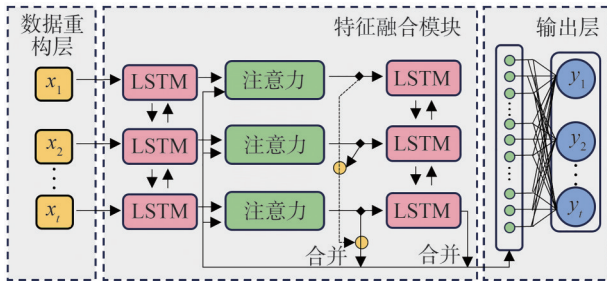


图 4 基于注意力机制的 LSTM 模型基本流程

Fig. 4 Basic process of the attention mechanism-based LSTM model

### 2.2 LSTM 模型

LSTM<sup>[23]</sup>通过引入遗忘门、输入门、输出门解决了传统循环神经网络(RNN)在长时间序列数据训练过程中的不稳定性问题,提高预测计算的稳定性。

1) 遗忘门<sup>[24-25]</sup>:通过权重矩阵与偏置的加权求和,动态决定前一时间刻航道水深状态中哪些信息需要被遗忘,具体公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

式中,  $f_t$  为遗忘权重,  $W_f$  为遗忘门的权重,  $h_{t-1}$  为  $t-1$  时刻的隐藏状态,  $b_f$  为遗忘门的偏置值,  $\sigma(\cdot)$  为 Sigmoid 函数。

2) 输入门<sup>[25]</sup>:对当前潮汐水位、流速、日降雨量等特征信息进行选择,确定哪些特征需要更新至当前水深状态。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\bar{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

式(3)、(4)中:  $i_t$  为输入值;  $W_i$  为输入门的权重;  $b_i$  为输入门的偏置值;  $\bar{C}_t$  为候选航道水深状态,用于表示当

前时刻的信息;  $W_c$  为内部状态的权重;  $b_c$  为内部状态的偏置值。

3) 输出门<sup>[25]</sup>:通过对当前水深状态的权重加权计算,提取与预测目标最相关的信息,用于生成下一时刻的水深预测值:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

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

式(5)、(6)中,  $W_o$  为输出门的权重,  $b_o$  为输出门的偏置值,  $o_t$  为输出值,  $C_t$  为  $t$  时刻的记忆状态,  $h_t$  为  $t$  时刻的隐藏状态。

### 2.3 注意力机制

不同输入的特征向量对预测结果的重要性各不相同<sup>[26]</sup>。传统 LSTM 模型在处理上述非线性动态关系时,难以有效捕捉关键特征参数<sup>[27]</sup>。对此,本文引入注意力机制,通过动态分配潮流流速、潮汐水位等水文特征向量的权重,增强模型水文特征向量在不同龄期的重要性识别,从而提高模型在多龄期条件下的预测能力。注意力机制通过查询(query)、键(key)和值(value)的映射关系实现特征的加权组合,其计算过程如下<sup>[28]</sup>。

$$Q = XW^Q \quad (7)$$

$$K = XW^K \quad (8)$$

$$V = XW^V \quad (9)$$

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (10)$$

式(7)~(10)中:  $X$  为 LSTM 提取的时间序列特征矩阵;  $W^Q$ 、 $W^K$  和  $W^V$  分别为可训练的权重矩阵,分别用于生成查询向量  $Q$ 、键向量  $K$  和值向量  $V$ ;  $d$  为键向量  $K$  的维度;  $\text{Attention}(\cdot)$  为注意力计算函数;  $\text{softmax}(\cdot)$  为归一化指数函数。

### 2.4 LSTM 模型训练

在训练过程中,为评估模型的预测精度,采用平均绝对误差(MAE,记为  $E_{\text{MAE}}$ )、均方根误差(RMSE,记为  $E_{\text{RMSE}}$ )和决定系数( $R^2$ )作为评价指标<sup>[29-30]</sup>。评价指标计算如下:

$$E_{\text{MAE}} = \frac{1}{N} \sum_{t=1}^N |y_t^{\text{true}} - y_t^{\text{pred}}| \quad (11)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t^{\text{true}} - y_t^{\text{pred}})^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (y_t^{\text{true}} - y_t^{\text{pred}})^2}{\sum_{t=1}^N (y_t^{\text{true}} - \bar{y})^2} \quad (13)$$

式(11)~(13)中,  $y_t^{\text{true}}$  为真实水深值,  $y_t^{\text{pred}}$  为模型的预

测值,  $\bar{y}$  为真实水深的算术平均数,  $N$  为训练样本数。

$R^2$  越接近 1, 回归效果越显著, 模型预测结果越准确。 $E_{RMSE}$  和  $E_{MAE}$  分别用于计算模型误差的均方根和平均幅度。与  $R^2$  不同,  $E_{RMSE}$  和  $E_{MAE}$  的值越小表明模型性能越好。

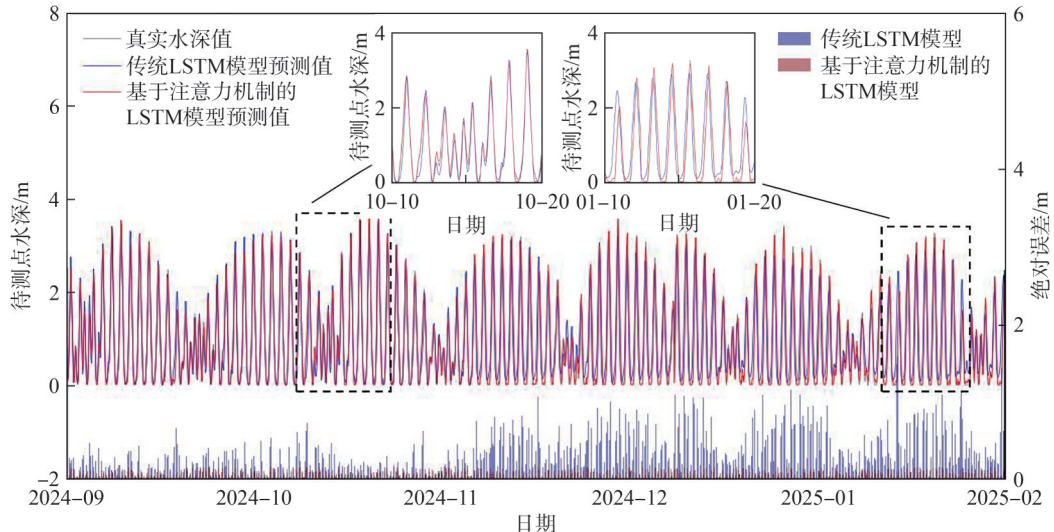
### 3 对比验证分析

#### 3.1 同类模型预测性能对比分析

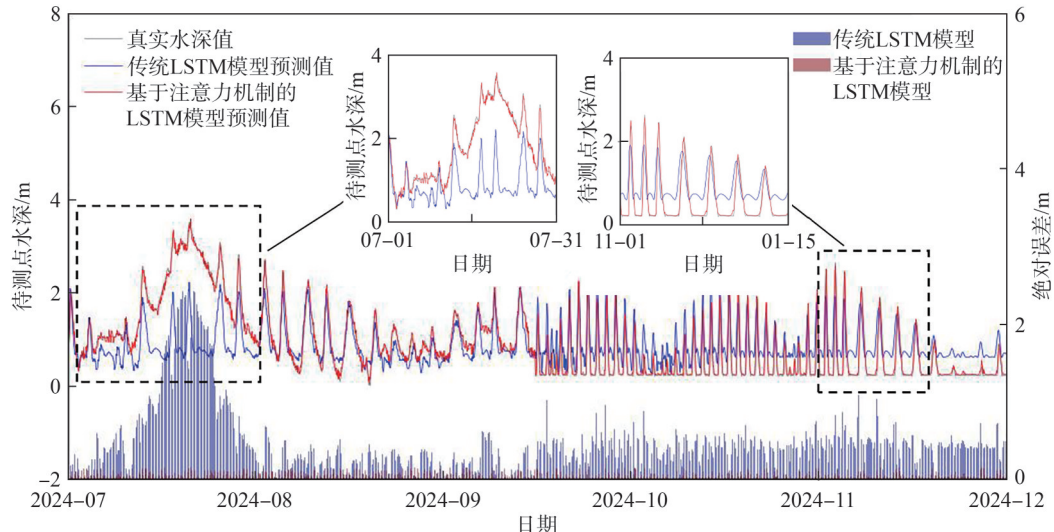
为验证本文提出的基于注意力机制的LSTM模型在航道水深预测的适用性, 将其与传统LSTM模型进行对比分析, 对比不同模型在捕捉时间序列特征、预测水深变化趋势以及适应复杂水文环境方面的表现。以距离内海 5 km 的钦江大桥测点(测点 1)和距离内海 30 km 的金海湾大桥测点(测点 2)的数据进行对比分

析。数据包括上游流量、日降雨量、潮流流速、潮汐水位及待测点水深。

本文模型在传统LSTM模型的基础上引入多头注意力机制, 设置 5 个注意力头, 每个注意力头维度为 64, 训练参数如下: 优化器 Adam, 学习率 0.001, 批量大小取 50, 迭代次数取 100。训练集时间范围为 2023 年 1 月—2024 年 7 月。训练后的模型用于预测 2024 年 7 月—2025 年 2 月的数据。图 5 为传统 LSTM 模型与基于注意力机制的 LSTM 模型训练结果对比分析。由图 5(a)可知, 随着预测日期远离训练日期, 传统 LSTM 模型的预测误差逐渐增大。在短期预测时, 预测的绝对误差为 0.07~1.08 m, 而长期预测时, 预测的绝对误差为 0.12~1.74 m, 且整体偏高估, 表明传统 LSTM 模型对长时间的预测精度较低。由图 5(b)可知, 当预测日期位于强降雨、偶发性上游泄



(a) 测点1训练结果



(b) 测点2训练结果

图5 传统LSTM模型与基于注意力机制的LSTM模型训练结果对比分析

Fig. 5 Comparison and analysis of training results between traditional LSTM model and LSTM model based on attention mechanism

洪的雨季时(2024年7月—10月)时,传统 LSTM 模型的预测结果普遍低估了水深值,预测的绝对误差为 0.53~2.67 m,且长期预测时,预测的绝对误差为 0.06~1.12 m,整体偏高估,表明传统 LSTM 模型不仅在预测长期水深时精度较低,而且在面对突发性波动时预测效果较差。相比之下,本文模型在不同日期、突发事件下的预测绝对误差均不超过 0.15 m,表明引入注意力机制后,模型能够动态感知雨季降雨、上游泄洪等突发事件对航道水深预测的关键作用,对短期波动及长期趋势的捕捉能力均有显著提升。

为进一步评估不同水文条件(枯水期和丰水期)对模型预测精度的影响,同样采用传统 LSTM 模型和基于注意力机制的 LSTM 模型进行对比分析。分别在丰水期和枯水期各取 200 个样本进行预测。图 6 和 7 分

别为传统 LSTM 模型和基于注意力机制的 LSTM 模型训练结果。由图 6 可见,在枯水期和丰水期时,模型预测的  $E_{MAE}$  分别为 0.125 7 和 0.184 5,  $E_{RMSE}$  分别为 0.165 3 和 0.226 6, 决定系数  $R^2$  分别为 0.976 2 和 0.943 2。由此可见,传统 LSTM 模型在枯水期的预测精度较高,且相较丰水期,其精度有所提高。这表明该模型对日降雨量、上游流量两个特征参数较为敏感。由图 7 可见,本文模型在枯水期和丰水期的预测精度与传统 LSTM 模型相比均得到了显著的提升,枯水期和丰水期水深预测的  $E_{MAE}$  分别降低了 64.68% 和 72.36%,  $E_{RMSE}$  分别降低了 67.51% 和 73.39%, 决定系数  $R^2$  分别提高了 2.18% 和 5.60%。表明模型在不同水文地质条件下预测效果均较好,且对日降雨量、上游流量两个特征参数不敏感。

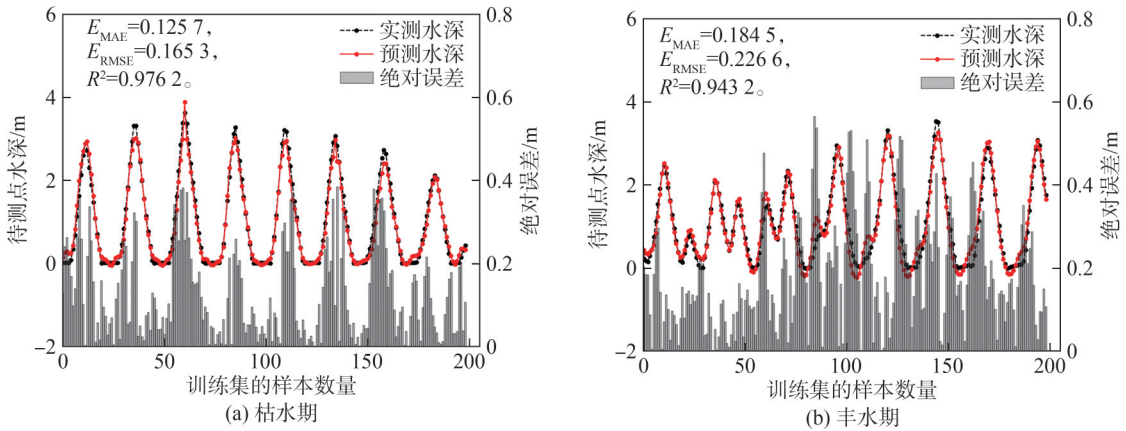


图 6 传统 LSTM 模型训练结果

Fig. 6 Training results of traditional LSTM model

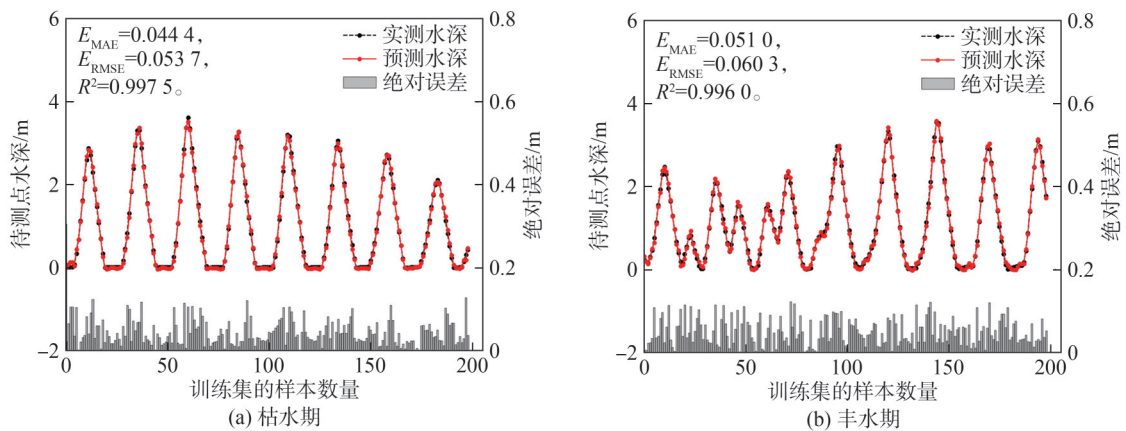


图 7 基于注意力机制的 LSTM 模型训练结果

Fig. 7 Training results of attention mechanism-based LSTM model

综合上述分析可知,两种模型存在异性的主要原因如下:首先,传统 LSTM 模型对较远时间步的信息传递效果较差,精度随时间推移逐渐降低;其次,传统 LSTM 适用于较为平稳的周期性规律分析,难以应对雨季、上游泄洪等临时突发性波动对预测的影响。相比之下,本文引入注意力机制,使模型能够在复杂时

间序列中更精准地聚焦于关键时刻的信息,尤其在波动性或非线性关系较强的情况下,表现尤为突出。

### 3.2 输入特征数量对预测精度影响分析

为进一步分析输入特征数量对模型预测精度的影响,本文通过不同数量的特征输入进行分析,分别使用包含上游流量、日降雨量、潮流流速和潮汐水位

4个特征向量(分别简记为 $S$ 、 $R$ 、 $C$ 、 $X$ )及待测点水深( $W$ )为标签进行训练并评估模型精度。数据集仍以第3.1节的样本为例。通过逐步增加输入特征数量,本文采用不同的组合方式,分别按特征数量1~4进行组合,共得到15种组合方式。图8和图9分别为 $E_{MAE}$ 和 $R^2$ 雷达图,采用极坐标系,直径越大, $E_{MAE}$ 和 $R^2$ 也越大。由图8可见,随着特征向量数量的增加,MAE的值呈现逐渐减小的趋势。其中,由图8(a)可见,在枯水期时, $S-R-C-X$ 、 $R-C-X$ 、 $S-C-X$ 和 $C-X$ 组合下 $E_{MAE}$ 均较小,分别为0.07、0.14、0.15和0.17。反之,其他特征组合的 $E_{MAE}$ 普遍较大,且均不小于0.66,表明在枯水期水文地质环境下潮流流速和潮汐水位对预测精度的影响较为显著,而上游流量和日降雨量的影响权重较

小。由图8(b)可见,在丰水期时, $S-R-C-X$ 、 $S-R-X$ 、 $S-C-X$ 和 $R-C-X$ 组合的MAE值均较小,分别0.04、0.10、0.17和0.15。相比之下,其他特征组合的 $E_{MAE}$ 均较大,且整体均不小于0.33,表明丰水期水文地质环境条下潮汐水位对模型预测精度的影响较为显著,且上游流量和日降雨量二者影响相同。由图9可见,在单一特征输入时,模型的预测精度较低,决定系数 $R^2$ 约为0.50。当增加第3个特征时,模型精度明显提高, $R^2$ 均超过0.91,且当特征向量按日降雨量/上游流量、潮流流速和潮汐水位特征组合时, $R^2$ 均不低于0.99。然而,当加入第4个特征(即日降雨量或上游流量)后, $R^2$ 稳定在0.995,说明加入日降雨量或上游流量作为第4个输入特征对模型精度的提升不显著。




图8 MAE雷达图

Fig. 8 Radar chart of MAE

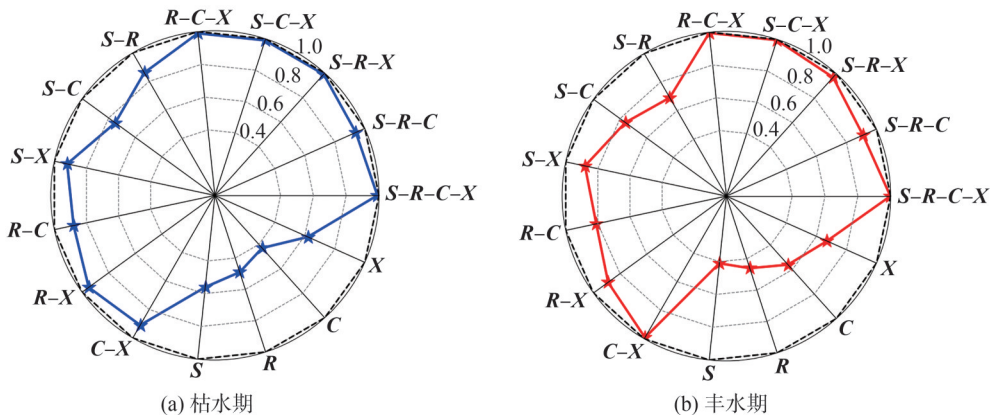


图9  $R^2$ 雷达图

Fig. 9 Radar chart of  $R^2$

日降雨量可通过天气预报提前获得,而上游流量仅可通过现场实时数据采集,作为预测特征的可获取性较差。鉴于此,本文最终选择日降雨量、潮流流速和潮汐水位作为主要特征向量。

### 4 平台工程应用

#### 4.1 平台开发

为便于工程应用,基于本文所提出的基于注意力

机制LSTM模型开发了航道运输辅助决策平台。图10为航道运输辅助决策平台前端界面。由图10可见,平台集成了多种核心功能模块,包括运输窗口期分析、环境监测、三维地形建模和实时水深变化预测等。主要功能如下。

1)航道水深预测:在水文条件平稳期,模型基于潮汐水位、潮流流速预测未来时段航道测点水深情况,水深视角覆盖整体航道。当气象站发布暴雨预警

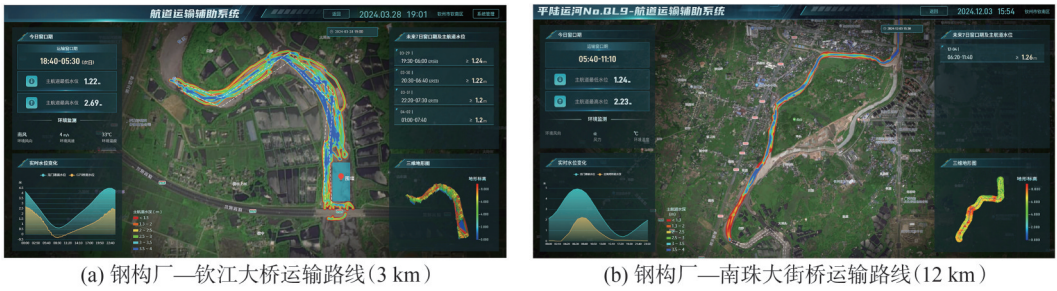


图 10 航道运输辅助决策平台前端界面

Fig. 10 Waterway transport assistance decision-making platform front-end interface

或监测点出现流量剧增等突发情况时,系统动态引入日降雨量、流量重新修正模型计算结果。

2)航道水深修正:通过接口协议连接测点水位计,自动接收并上传实时水深数据,实现水深变化超过±5 cm的动态修正。

3)通航窗口期评估:基于阈值条件筛选符合要求的时间段,利用动态时间分割算法识别连续运输窗口,并计算每个窗口的总持续时间,最终筛选出有效的运输窗口期。

4)通航船舶预警:基于图像识别,通过关键闸口的船舶参数,结合北斗卫星导航定位船舶具体位置,

实时计算最佳通航路线,避开水深不足的区域,当船舶接近吃水深度临界值时自动报警。

### 4.2 工程应用

目前,基于带注意力机制的LSTM模型和航道运输辅助决策平台已在平陆运河多条航道运输管理中得到实际应用。表1为航道运输辅助决策平台应用前后效果对比。由表1可见,与传统方法相比,通过多模块协同工作,本文方法在多项关键应用中展现出更高的精准度和可操作性,显著提高了施工安全和运输效率,为航道运输智能化和数字化管理提供了强有力的技术支持。

表1 航道运输辅助决策平台功能及应用前后效果对比

Tab. 1 Function and comparison of pre-and post-application effects of the waterway transport assistance decision-making platform

功能应用模块	特点	应用前	应用后
水下地形建模	利用GIS+超高频点云声呐技术实现运输航道水下地形精细化建模	测点较为稀疏,两测点间地形起伏程度不明确	点云测点较为密集,且无突变点,对危险点定位准确
通航窗口期预测	通航窗口期可根据实时水位变化及船舶吃水深度自适应调整	通过潮汐表、天气预报人为预测未来通航窗口期,预测精度较差	自动化程度和预测精度较高,且可根据窗口期提前安排航道运输计划
桥下通航评估	通过桥下设计净高与当前水深、船舶吃水及高度的关联性,评估桥下通航能力	通过安排人员主观判断,通航过程较为缓慢	可提前告知桥底通航安全时间,并在接近桥底前发出通航许可
航道危险水深预警	可提前规划运输船通航路线,避免发生触礁、搁浅等现象	通过安全船在前方探路预警,对航道水深不明确位置响应较慢	提前告知运输船通航路线,若局部水深不允许时,预警响应迅速

## 5 结论

基于平陆运河长时间序列水文数据,提出了一种

基于注意力机制的LSTM模型,构建面向复杂滨海区域的水深预测方法,并应用于航道运输辅助决策平台,最终在实际工程中进行应用验证。分析结果表明:

1) 基于注意力机制的 LSTM 模型在预测过程中,  $E_{MAE}$  均维持在 0.15 m 以内, 与传统 LSTM 模型相比, 枯水期和丰水期水文地质环境条件下水深预测的  $E_{MAE}$  分别降低了 64.68% 和 72.36%, 决定系数  $R^2$  分别提高了 2.18% 和 5.60%, 说明引入注意力机制显著提升了 LSTM 模型在复杂水文环境中的预测精度与稳定性。

2) 将水文特征向量按不同方式组合后, 本文模型的预测精度整体上均优于传统 LSTM 模型。此外, 与单一特征模型相比, 采用 3 特征(日降雨量、潮流流速和潮汐水位)组合模型的预测 MAE 不超过 0.15 m, 决定系数  $R^2$  不低于 0.99, 说明 3 特征组合模型提升了对滨海航道水深预测的适应性, 计算精度较为稳定。

3) 将本文模型集成至航道运输辅助决策平台中, 实现了水深预测及动态修正、通航窗口期评估和船舶预警等多模块协同, 提高航道运输智能化和数字化管理水平, 为后续工程提供了可靠的技术支持。

#### 参考文献:

- [1] Xing Changli. Discussion on supervision mode of water traffic safety of Hong Kong-Zhuhai-Macao Bridge[J]. *Railway Engineering*, 2014, 54(7): 15-18. [邢长利. 港珠澳大桥水上交通安全监管模式探讨[J]. *铁道建筑*, 2014, 54(7): 15-18.]
- [2] Liu Huaihan, Yang Shengfa, Cao Minxiong. Advances in 'golden waterway' regulation technologies of the Yangtze River[J]. *Advanced Engineering Sciences*, 2017, 49(2): 17-27. [刘怀汉, 杨胜发, 曹民雄. 长江黄金航道整治技术研究构想与展望[J]. *工程科学与技术*, 2017, 49(2): 17-27.]
- [3] Lyu Xiaolong, Wu Peng, Liu Xiaoling. Demonstration on waterway classification of Pinglu canal[J]. *Port & Waterway Engineering*, 2021(10): 266-270. [吕小龙, 吴澎, 刘晓玲. 平陆运河航道等级论证[J]. *水运工程*, 2021(10): 266-270.]
- [4] Gan Min, Chen Yongping, Pan Shunqi, et al. A modified nonstationary tidal harmonic analysis model for the Yangtze estuarine tides[J]. *Journal of Atmospheric and Oceanic Technology*, 2019, 36(4): 513-525.
- [5] Barzegar R, Fijani E, Asghari Moghaddam A, et al. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models[J]. *Science of the Total Environment*, 2017, 599: 20-31.
- [6] Dian Songyi, Li Xiaoying, Yang Dan, et al. Adaptive robust prediction of groundwater level based on fusion attention mechanism LSTM network[J]. *Advanced Engineering Sciences*, 2024, 56(1): 54-64. [佃松宜, 厉潇滢, 杨丹, 等. 基于融合注意力机制 LSTM 网络的地下水位自适应鲁棒预测[J]. *工程科学与技术*, 2024, 56(1): 54-64.]
- [7] Hou Jingming, Wang Yu, Zhang Zhaoan, et al. Inflow boundary optimized method in two-dimensional hydrodynamic model[J]. *Advanced Engineering Sciences*, 2022, 54(4): 39-46. [侯精明, 汪煜, 张兆安, 等. 2 维水动力模型中入流边界优化处理方法[J]. *工程科学与技术*, 2022, 54(4): 39-46.]
- [8] Gribovszki Z, Kalicz P, Szilágyi J, et al. Riparian zone evapotranspiration estimation from diurnal groundwater level fluctuations[J]. *Journal of Hydrology*, 2008, 349(1/2): 6-17.
- [9] Chen Yifan, Cao Feifeng, Meng Xiangyong, et al. Water level simulation in river network by data assimilation using ensemble Kalman filter[J]. *Applied Sciences*, 2023, 13(5): 3043.
- [10] Almikael W, Šoltész A, Čubanová L, et al. Hydro-informer: A deep learning model for accurate water level and flood predictions[J]. *Natural Hazards*, 2025, 121(4): 3959-3979.
- [11] Ma Xin, Hu Hao, Ren Yufeng. A hybrid deep learning model based on feature capture of water level influencing factors and prediction error correction for water level prediction of cascade hydropower stations under multiple time scales[J]. *Journal of Hydrology*, 2023, 617: 129044.
- [12] Zhang Qixiao, Li Peiyue, Ren Xiaofei, et al. A new real-time groundwater level forecasting strategy: Coupling hybrid data-driven models with remote sensing data[J]. *Journal of Hydrology*, 2023, 625: 129962.
- [13] Sun Wei, Chang L C, Chang F J. Deep dive into predictive excellence: Transformer's impact on groundwater level prediction[J]. *Journal of Hydrology*, 2024, 636: 131250.
- [14] Lyu Haifeng, Ji Xiaoyu, Ding Yong. Research on Xijiang River water level prediction model of multi-factor based on splice-LSTM[J]. *Yangtze River*, 2023, 54(7): 81-88. [吕海峰, 冀肖榆, 丁勇. 基于 splice-LSTM 的多因素西江水位预测模型研究[J]. *人民长江*, 2023, 54(7): 81-88.]
- [15] Liu Xiaolei, Liu Yifan, Wang Shuaifei, et al. New canal construction and marine emissions strategy: A case of Pinglu[J]. *Frontiers in Marine Science*, 2024, 10: 1303879.
- [16] Xin Jingzhou, Zhou Chaoying, Jiang Yan, et al. A signal recovery method for bridge monitoring system using TVFEMD and encoder-decoder aided LSTM[J]. *Measurement*, 2023, 214: 112797.
- [17] Martin Nascimento G F, Wurtz F, Kuo-Peng P, et al. Outlier detection in buildings' power consumption data using forecast error[J]. *Energies*, 2021, 14(24): 8325.
- [18] Ma Ruixin, Yin Yong, Bao Kexin, et al. Water level prediction of inland waterways based on MHA-BiGRU[J]. *Journal of Dalian Maritime University*, 2024, 50(1): 46-56. [马瑞鑫, 尹勇, 鲍可馨, 等. 基于 MHA-BiGRU 的内河航道水位预测分析[J]. *大连海事大学学报*, 2024, 50(1): 46-56.]
- [19] Tian Zhongda, Yu Xiyan, Feng Guokui. Short-term wind speed prediction model based on long short-term memory

- network with feature extraction[J]. *Earth Science Informatics*, 2025, 18(4): 333.
- [20] Zhang Qi, Miao Chiyan, Gou Jiaojiao, et al. Spatiotemporal characteristics and forecasting of short-term meteorological drought in China[J]. *Journal of Hydrology*, 2023, 624: 129924.
- [21] He Guangxin, Qu Haifeng, Luo Jingjia, et al. An long short-term memory model with multi-scale context fusion and attention for radar echo extrapolation[J]. *Remote Sensing*, 2024, 16(2): 376.
- [22] Li Haoran, Zhang Lili, Zhang Yaowen, et al. Water-level prediction analysis for the Three Gorges Reservoir area based on a hybrid model of LSTM and its variants[J]. *Water*, 2024, 16(9): 1227.
- [23] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735–1780.
- [24] Le Q V, Jaitly N, Hinton G E. A simple way to initialize recurrent networks of rectified linear units[EB/OL]. (2015–04–07)[2025–01–15]. <https://arxiv.org/abs/1504.00941>.
- [25] Zhang Wenming, Feng Dandian, Ge Yaojun. Nonlinear aerodynamic force model of bridge based on deep learning[J]. *Bridge Construction*, 2023, 53(3): 16–24. [张文明, 冯丹典, 葛耀君. 基于深度学习的桥梁非线性气动力模型研究[J]. *桥梁建设*, 2023, 53(3): 16–24.]
- [26] Huang Ying, Xu Jian, Zhou Ziqi, et al. Research and implementation of efficient long sequence model for water level forecasting[J]. *Journal of University of Electronic Science and Technology of China*, 2023, 52(4): 595–601. [黄颖, 许剑, 周子祺, 等. 高效长序列水位预测模型的研究与实现[J]. *电子科技大学学报*, 2023, 52(4): 595–601.]
- [27] Bahdanau D, Cho K, Bengio Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2015–04–07)[2025–01–15]. <https://arxiv.org/abs/1409.0473>.
- [28] Zeng Yan, Feng Dongming, Li Jian'an. Vehicle-assisted bridge damage assessment by combining attention mechanism and Bi-LSTM network[J]. *Journal of Vibration Engineering*, 2024, 37(7): 1089–1097. [曾琰, 冯东明, 黎剑安. 融合注意力机制和Bi-LSTM网络的车辆辅助桥梁损伤评估[J]. *振动工程学报*, 2024, 37(7): 1089–1097.]
- [29] Ehteram M, Ghanbari-Adivi E. Self-attention (SA) temporal convolutional network (SATCN)-long short-term memory neural network (SATCN-LSTM): An advanced Python code for predicting groundwater level[J]. *Environmental Science and Pollution Research*, 2023, 30(40): 92903–92921.
- [30] Li Xiaogen, Liu Hongchen, Fu Jingbao, et al. Groundwater level prediction based on CNN-Attention-LSTM model[J]. *Water Resources Protection*, 2025, 41(4): 228–235. [李小根, 刘泓辰, 付景保, 等. 基于CNN-Attention-LSTM模型的地下水水位预测[J]. *水资源保护*, 2025, 41(4): 228–235.]

## Research on Multi-factor Coastal Waterway Depth Prediction and Application Based on Attention-enhanced LSTM Model

LING Ganzhan<sup>1,2</sup>, HAN Yu<sup>1</sup>, XIE Weiwei<sup>1,2\*</sup>, TANG Ruikai<sup>1,2</sup>, HU Jiakai<sup>1</sup>, LIANG Guangyue<sup>1</sup>, CAO Lu<sup>1</sup>, LIANG Ming<sup>1</sup>, LIU Xiang<sup>1</sup>

(1. Guangxi Road and Bridge Engineering Group Co., Ltd., Nanning 530200, China;  
2. School of Civil Engineering and Architecture, Guangxi University, Nanning 530004, China)

### Abstract:

**Objective** Accurate prediction of water depth in coastal waterways is essential for ensuring the safety and efficiency of construction and transportation activities, particularly in environments characterized by complex and dynamic hydrological conditions. The Pinglu Canal, an inland waterway affected by tidal influences, serves as an example where traditional prediction models fail to accurately forecast water depth under complex hydrological conditions. This study presents a water depth prediction model based on an attention-enhanced long short-term memory (LSTM) network, which is integrated into a decision-support platform for real-time channel transportation management.

**Methods** First, key hydrological factors, including upstream discharge, daily rainfall, tidal current velocity, and tidal level, were incorporated to construct the LSTM-based coastal waterway depth prediction model. The raw hydrological data were preprocessed to address issues such as missing values, noise, and irregular time intervals, ensuring suitability for time-series modeling. Then, the LSTM model was utilized to capture the long-term temporal dependencies within the data, allowing the model to account for complex interactions among various hydrological variables over time. An attention mechanism was introduced to optimize the model's performance. This mechanism improved the model architecture by enabling it to dynamically adjust the weight of each feature at every time step, prioritizing the most relevant factors based on the current data. The attention mechanism enhanced both the accuracy and stability of the model, particularly for ultra-long-term water depth forecasting under dynamic and complex coastal hydrological conditions. Finally, the optimized model was embedded into a transportation decision-support platform, allowing for real-time water depth prediction, dynamic correction of forecasts based on new data, and navigable time window evaluation. The model's effectiveness was validated through comparative analyses with existing prediction models and field measurements, demonstrating supe-

rior accuracy and reliability in predicting waterway depth.

**Results and Discussions** The results demonstrated that at two monitoring points, 5 km from the coast (Point 1) and 30 km inland (Point 2), the traditional LSTM model exhibited larger prediction errors, especially in long-term forecasts. The MAE ranged from 0.07 m to 1.08 m for short-term predictions and from 0.12 m to 1.74 m for long-term forecasts. The model also tended to overestimate water depth. In contrast, the attention mechanism-based LSTM model consistently kept the MAE below 0.15 m, even under sudden rainfall or upstream discharge events, showing enhanced accuracy in both short-term fluctuations and long-term trends. The model's performance across seasonal variations further highlighted its robustness. During the dry season, the MAE was reduced by 64.68%, and during the wet season, it decreased by 72.36%. The RMSE was also reduced by 67.51% and 73.39% in the respective seasons, while the  $R^2$  coefficient improved by 2.18% and 5.60%. This demonstrated the model's adaptability to both stable and volatile water conditions. The attention mechanism-based LSTM model significantly outperformed traditional LSTM models in predicting waterway depth. Compared to the traditional model, the MAE of was reduced by 65.00%~72.00%, and the  $R^2$  coefficient increased by 2.20%~5.60%, demonstrating superior predictive accuracy and stability. This improvement was particularly evident under complex hydrological conditions, where the model effectively captured non-linear and dynamic relationships among key features such as tidal flow speed, daily rainfall, and tidal water level. In addition, when compared to a single feature vector model, the three-feature vector combination (daily rainfall, tidal flow speed, and tidal water level) resulted in an MAE of no more than 0.15 m and an  $R^2$  coefficient of no less than 0.99, substantially improving the model's accuracy and stability for predicting waterway depth under complex coastal hydrological conditions. Finally, when integrated into the waterway transportation decision-support platform, the model's capabilities, such as real-time water depth prediction, dynamic correction, and navigable time window evaluation, substantially enhanced the platform's effectiveness. This integrated system provided reliable and accurate information for waterway transportation management, contributing to safer and more efficient navigation in complex coastal environments.

**Conclusions** This study presents an attention mechanism-based LSTM model for predicting waterway depth in complex coastal environments. The proposed model substantially improves prediction accuracy and stability, especially under dynamic hydrological conditions. The model effectively adapts to diverse waterway conditions by incorporating key hydrological features, ensuring higher precision in depth forecasting. When implemented within a waterway transportation decision-support platform, the model enables real-time prediction, dynamic correction, and navigable time window assessment, enhancing the intelligence and digital management of waterway transportation systems. This research provides reliable technical support for future engineering applications.

**Key words:** Pinglu Canal; waterway construction and transportation; waterway depth prediction; attention mechanism; LSTM model; waterway transportation decision support platform

(编辑 陈 雪)

引用格式: Ling Ganzhan, Han Yu, Xie Weiwei, et al. Research on multi-factor coastal waterway depth prediction and application based on attention-enhanced LSTM model[J]. *Advanced Engineering Sciences*, 2026, 58(1): 266–275. [凌干展, 韩玉, 解威威, 等. 基于注意力机制的LSTM多因素滨海航道水深预测及应用研究[J]. *工程科学与技术*, 2026, 58(1): 266–275.]