



# 融合物理机制与稀疏数据驱动的 泥沙输运预测模型研究

谭欣扬, 汪承志, 赵桑岚  
(重庆交通大学 河海学院, 重庆 400074)

**摘要:** 针对港池航道泥沙淤积预测中传统物理模型计算成本高、数据驱动模型泛化能力弱等问题, 开展融合物理机制与稀疏数据驱动的泥沙输运预测方法研究。通过构建物理引导的长短期记忆网络(PhyLSTM), 将泥沙输运-扩散方程与床面演变模型中的关键物理参数(如扩散系数、源汇项等)转化为可学习变量, 并嵌入床面变化趋势作为物理先验知识引导网络学习非线性动态过程。基于某典型港池3a连续监测的1440组多日数据(0.002 5°×0.002 5°网格划分), 对比分析PhyLSTM与传统LSTM模型的预测性能。结果表明, PhyLSTM模型在全区预测中平均绝对误差为0.0915 m, 均方根误差为0.1145 m, 平均相对百分误差为0.75%, 分别较LSTM模型降低了37%、30%和36%; 预测误差在±0.2 m范围内的样本占比达91.74%, 较LSTM模型提升了10.18%。该方法为港池航道淤积预测提供了兼具高精度与可解释性的新路径, 对优化港口疏浚决策、降低维护成本具有重要的工程价值。

**关键词:** 泥沙疏浚; 淤积预测; 稀疏数据; 物理机制; LSTM模型

中图分类号: U617.6

文献标志码: A

文章编号: 1002-4972(2026)02-0020-09

## Sediment transport prediction model integrating physical mechanism and sparse data-driven approach

TAN Xinyang, WANG Chengzhi, ZHAO Sanglan

(College of River and Ocean Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

**Abstract:** In response to the challenges of high computational cost associated with traditional physics-based models and the poor generalization of purely data-driven methods in predicting sedimentation in port basin channels, a hybrid sediment transport prediction framework that integrates physical principles with sparse data-driven learning is proposed. The physics-guided long short-term memory (PhyLSTM) model built in this paper is incorporated key physical parameters from sediment transport-diffusion equation and bed evolution model (such as the diffusion coefficient and source-sink term, etc.) as learnable variables. The bed elevation trend is also embedded as a physical prior to guide the learning of nonlinear sediment dynamics. Using 1,440 sets of multi-day monitoring data collected over three years from a typical port basin (0.002 5°×0.002 5° grid), the prediction performance of PhyLSTM is compared with a traditional LSTM model. The results show that the PhyLSTM model achieves a mean absolute error of 0.0915 m, a root mean square error of 0.1145 m, and a mean absolute percentage error of 0.75%, representing reductions of 37%, 30%, and 36% with the traditional LSTM model, respectively. Additionally, 91.74% of predictions fall within a ±0.2 m error range, 10.18% higher than that of the LSTM. The proposed method offers a novel, interpretable, and accurate approach for predicting sedimentation in port basin channels, which holds substantial engineering value for optimizing port dredging strategies and minimizing maintenance expenses.

**Keywords:** sediment dredging; siltation prediction; sparse data; physical mechanism; LSTM model

收稿日期: 2025-05-27 录用日期: 2025-07-11

作者简介: 谭欣扬(2001—), 女, 硕士研究生, 研究方向为港口、海岸及近海工程。

港池进出口航道泥沙淤积是影响港口运行效率与安全的重要因素,淤积不仅导致通航水深不足,还增加了港口疏浚频率和维护成本。随着海陆业务的快速增长与港口作业自动化水平的提升,对航道水深预测的时效性与精度提出更高的要求。

传统泥沙预测方法可分为两类:1)基于泥沙动力学的物理模型,如曹祖德等<sup>[1]</sup>建立3层淤积计算模式用于计算黄啤港粉沙质海岸外航道淤积,其计算结果与现场实测值的误差在0.5 m以内;张钰等<sup>[2]</sup>、Tamang等<sup>[3]</sup>、朱沈鸣等<sup>[4]</sup>建立的二维水力模型,对研究区域进行潮位、流速和含沙量模拟,结果与实测基本吻合。物理模型具有较强的可解释性和理论基础<sup>[5-6]</sup>,但需要大量的水文数据与边界条件,计算成本高、适应性差。2)基于数据驱动的机器学习与深度学习<sup>[7]</sup>,Kaveh等<sup>[8]</sup>采用长短期记忆(long-short term memory,LSTM)模型预测悬沙浓度,进一步提升预测模型的准确率;香天元等<sup>[9]</sup>提出将LSTM神经网络耦合的水沙模拟模型的方法,取得较高的预测精度。深度学习模型具有灵活性强、建模能力强的优势,但常忽略泥沙运动的物理机制,缺乏泛化能力与物理可解释性。因此,亟需发展一种兼具物理可靠性与数据驱动效率的预测模型。

近年来,融合物理机制的神经网络模型在水文水资源、环境建模及海洋工程等领域受到广泛关注<sup>[10-11]</sup>。相较于传统的纯数据驱动方法,该类模型通过嵌入物理定律、经验方程或物理约束特征,提升模型的泛化能力和预测可信度。Ohara等<sup>[12]</sup>通过将运动控制方程、连续性方程以及基于质量守恒原理的恒定流量条件作为物理约束集成到神经网络中,此模型能够在数据稀缺的情况下,准确预测河床的演变过程;Guo等<sup>[13]</sup>提出一种结合物理机制模型与LSTM网络的优化组合策略,研究结果均方根误差(root mean square error, RMSE)降低62.68%,有效提高了日径流预测准确性。这些研究表明,物理引导神经网络不仅提高了预测精度,更增强了模型对未知场景的泛化能力与解释力。

因此,本文提出一种融合物理机制的长短期记忆网络(physics-guided long short-term memory, PhyLSTM)模型,通过引入泥沙运输-扩散模型与床面演变模型中反映实际物理过程的核心机制,构建可学习的物理先验模块,并将其嵌入LSTM网络的输入和注意力结构中。旨在解决长历时稀疏历史数据的港池航道泥沙淤积预测中的精度和泛化瓶颈。该方法兼具物理模型的可解释性与数据驱动模型的建模灵活性,在数据稀疏或边界变化条件下保持预测的稳定性和泛化能力,适用于港池航道等典型区域的泥沙淤积时序预测需求。

## 1 融合物理机制的淤积预测神经网络

为实现对港池泥沙淤积演变过程的多步高精度预测,本文设计一种融合物理模型与深度学习的神经网络结构。整体模型由两个模块构成:物理子网络(physics net)和时序预测网络(LSTM predictor)。其中,物理子网络根据泥沙运输扩散理论快速估算泥沙淤积高度的变化趋势,作为先验信息引导LSTM网络建模时序演化特征。

### 1.1 泥沙运输-扩散模型

港池泥沙淤积是由水动力作用下泥沙的运输、沉降和再悬浮等过程共同作用的结果。为了准确模拟港池内泥沙淤积的空间分布和时间演化,采用二维泥沙运输模型对泥沙浓度和床面变化进行描述。港池内泥沙运输过程可由二维对流-扩散方程描述<sup>[14]</sup>,其基本形式为:

$$\frac{\partial C}{\partial t} + u \frac{\partial C}{\partial x} + v \frac{\partial C}{\partial y} = D_x \frac{\partial^2 C}{\partial x^2} + D_y \frac{\partial^2 C}{\partial y^2} + S(C) \quad (1)$$

式中: $C(x,y,t)$ 为港池内某位置泥沙浓度; $u(x,y,t)$ 、 $v(x,y,t)$ 为该位置的水流速度分量; $D_x$ 、 $D_y$ 为泥沙扩散系数; $S(C)$ 为源汇项,包含沉降与再悬浮等物理过程。

### 1.2 床面演变模型

床面演变模型源于Exner方程,是有关于河床沉积物的质量守恒定理<sup>[15]</sup>,在工程、水动力模

拟与学术研究中被广泛采用,适用于直接预测淤积高度。港池内水流较慢、扰动相对较小,满足床面演变模型中沉降与再悬浮通量为主导机制的假设。方程形式为:

$$\frac{\partial z_b}{\partial t} = \frac{1}{1-\lambda_p}(S_d - S_e) \quad (2)$$

式中:  $z_b$  为港池内某位置床面高程;  $\lambda_p$  为床面沉积物的孔隙率,通常取 0.35~0.50;  $S_d$  为沉降通量,通常形式为  $S_d = w_s C$ , 其中  $w_s$  为泥沙沉速,可近似为线性函数;  $S_e$  为再悬浮通量。

### 1.3 融合物理机制的泥沙淤积预测神经网络构建

以上物理公式含有经验系数,如式(1)的  $D_x$ 、 $S(C)$  易受环境扰动影响,式(2)所关联的  $w_s$  和  $S_e$  都存在较强的经验性。将经验系数、公式用含有可学习参数的网络层代替,即可根据实际数据自动学习出更好拟合的经验公式或者经验系数<sup>[16]</sup>。这样构建的网络不仅可以提高预测精度,还能加快训练的收敛过程<sup>[17]</sup>。

将  $D_x$ 、 $D_y$  设置为可训练参数,并将  $S(C)$  替换为可学习函数  $N_s(C)$ , 以卷积神经网络形式对其进行端到端建模。在床面演变模型中,分别引入两个神经网络模块  $N_d(C)$ 、 $N_e(C)$  对沉降通量项中的  $w_s$  及  $S_e$  进行建模,前者拟合沉降速率函数,后者用于学习剪应力激发再悬浮过程中的非线性响应。将式(1)、(2)改写为:

$$\frac{\partial C}{\partial t} = -\left(u \frac{\partial C}{\partial x} + v \frac{\partial C}{\partial y}\right) + D_x \frac{\partial^2 C}{\partial x^2} + D_y \frac{\partial^2 C}{\partial y^2} + N_s(C) \quad (3)$$

$$\frac{\partial z_b}{\partial t} = \frac{1}{1-\lambda_p} [N_d(C) - N_e(\tau_b)] \quad (4)$$

式中:  $N_s(C)$  为可学习源汇项;  $N_d(C)$  为可学习沉降通量;  $N_e(\tau_b)$  为可学习再悬浮激活函数。  $N_s(C)$ 、 $N_d(C)$ 、 $N_e(\tau_b)$  均是可训练参数。

模型首先接收历史时刻的二维流速场  $u(x,y,t)$ 、 $v(x,y,t)$ , 以及水深  $h(x,y,t)$ 、前一时刻的泥沙浓度分布  $C(x,y,t-1)$ , 通过卷积近似方式对二维输运-扩散方程进行数值化重构,输出当前时刻的浓度估计:

$$\hat{C}_t = f_{adv-diff}(u, v, h, C_{t-1}) \quad (5)$$

式中:  $f_{adv-diff}$  为嵌入物理导数结构的神经网络函数。

在获得浓度估计值  $\hat{C}_t$  后,结合水动力计算的剪应力  $\tau_b(x,y,t)$ , 代入以下床面演变方程:

$$\Delta z_b = \frac{1}{1-\lambda_p} [\theta_1 \hat{C}_t + \theta_2 f(\tau_b) + \theta_3] \quad (6)$$

式中:  $\theta_1$  为可学习泥沙沉速;  $\theta_2$  为再悬浮项;  $\theta_3$  为偏置项;  $f(\tau_b)$  为剪应力函数,可直接拟合为子网络。  $\theta_1$ 、 $\theta_2$ 、 $\theta_3$  均为可训练参数。

融合物理机制的淤积高程预测神经网络见图 1, 该模块输出当前时刻的床面淤积变化量  $\Delta z_b(x,y,t)$ 。根据已知的上一时刻床面高程  $z_b(x,y,t-1)$ , 将预测的变化量进行叠加, 获得当前时刻的床面高程  $z_b$ 。

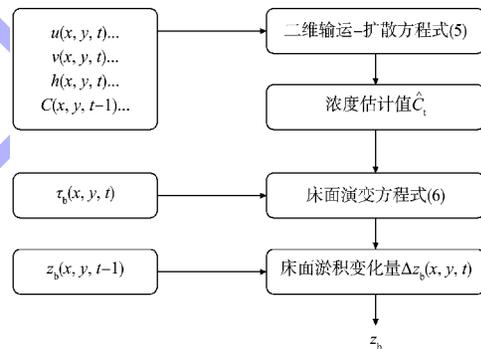


图 1 融合物理机制的淤积高程预测神经网络

Fig. 1 Sedimentation elevation prediction neural network integrating physical information

## 2 融合物理模型的港内航道泥沙淤积预测的 LSTM 网络

### 2.1 LSTM 网络

鉴于疏浚作业的周期性与规律性,已获得的数据具有显著的时序性,因此选择有良好的时间建模能力的 LSTM 模型,主要关注的变量包括经纬度和开挖高程。为弥补其在无物理解释的条件下容易过拟合的问题,引入由物理模块计算得到的床面变化趋势量  $\Delta z_b(t)$ , 并将其作为引导项嵌入 LSTM 网络的输入层,实现物理机制与时序特征的协同建模,PhyLSTM 结构见图 2。

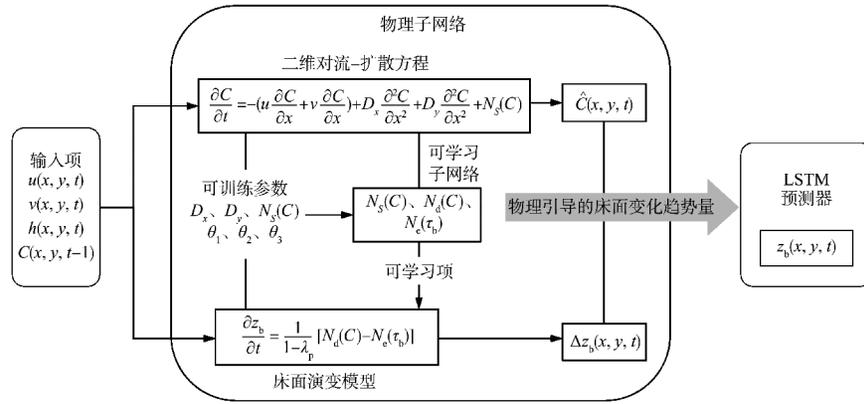


图2 PhyLSTM 结构

Fig. 2 PhyLSTM structure

由图2可知, 本模块的输入序列包含常规变量(床面高程  $z_b$ 、流速  $u$ 、 $v$ 、水深  $h$ ), 还融合了物理子网络输出的床面变化量  $\Delta z_b(t)$ 。所有变量在输入层拼接为一个时间维度上对齐统一的多维序列  $x'_t$ , 并输入至 LSTM 网络进行序列建模。最终, 将隐藏状态  $h_t$  送入全连接层(fully connected, FC), 生成未来  $n$  步的床面高程预测序列:

$$x'_t = [z_b(t), u(t), v(t), h(t), \Delta z_b(t)] \quad (7)$$

$$h_t = f_{\text{LSTM}}(x_t, h_{t-1}) = f_{\text{LSTM}}([z_b, u, v, h, \Delta z_b], h_{t-1}) \quad (8)$$

$$\hat{z}_b^{(t+1:t+n)} = C_F(h_t) \quad (9)$$

式中:  $\hat{z}_b^{(t+1:t+n)}$  为第  $t+1 \sim t+n$  时刻预测的泥沙淤积高程值;  $f_{\text{LSTM}}$  为 LSTM 函数;  $C_F$  为 FC 函数。

采用均方误差 MSE 作为主要的监督学习损失函数, 用于衡量预测值与实测值之间的偏差, 驱动网络参数的迭代更新。损失函数的定义如下:

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N |\hat{z}_b^{(i)} - z_b^{(i)}| \quad (10)$$

式中:  $\hat{z}_b^{(i)}$  为第  $i$  个样本预测的泥沙淤积高程;  $z_b^{(i)}$  为实测值;  $N$  为训练样本总数。

最终, 通过最小化上述损失函数, 网络在历史区域数据驱动下自动学习时序与空间演化规律, 实现对港池中泥沙淤积过程的多步有效预测。

## 2.2 评价指标

为验证所提出的融合嵌入式物理模块的 LSTM 模型在港池泥沙淤积多步预测中的有效性,

选用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、平均相对百分误差(mean absolute percentage error, MAPE) 3 种误差评价指标, 公式为:

$$E_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |\hat{z}_b^{(i)} - z_b^{(i)}| \quad (11)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{z}_b^{(i)} - z_b^{(i)})^2} \quad (12)$$

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{z}_b^{(i)} - z_b^{(i)}}{z_b^{(i)}} \right| \times 100\% \quad (13)$$

式中:  $E_{\text{MAE}}$  为平均绝对误差;  $E_{\text{RMSE}}$  为均方根误差;  $E_{\text{MAPE}}$  为平均相对百分误差;  $\hat{z}_b^{(i)}$  与  $z_b^{(i)}$  分别为模型预测值与实测值;  $N$  为样本总数。

## 3 数据与试验设置

### 3.1 历史数据

将航道按  $0.0025^\circ \times 0.0025^\circ$  划分网格, 去除非航道区域, 保留剩余的网格, 最后划分为 20 个区域见图 3。使用的数据源于某典型港池航道区域的连续监测结果, 采用循环测量方式进行数据采集, 每个区域每隔 20 d 观测 1 次。原始观测数据覆盖了连续时间段, 每次观测包含多个关键变量, 包括床面淤积高程  $z_b$ 、水深  $h$ 、二维流速  $u$ 、 $v$  与泥沙浓度  $C$ , 具有典型的时空非均匀性。根据航道内不同位置的浮泥分布厚度和淤积趋势情况不同, 可将 20 个网格大致可分为内港池、转角段、口门段、外航道 4 个区域, 见表 1。

表 1 区域淤积特性

Tab. 1 Siltation characteristics in area

区域(编号)	特征	回淤特性	典型区域
内港池(1#~12#)	港池内部,流速极低(约 0.1 m/s)	回淤迅速	3#、8#
转角段(13#~15#)	接近北防波堤拐角,流场复杂、泥沙积聚严重	浮泥厚度 2~3 m,淤积剧烈	13#、14#
口门段(16#)	接近港池口门,仍有一定外海交换	回淤中等	16#
外航道(17#~20#)	受潮流冲刷强,几乎无浮泥	水深稳定,淤积几乎不变	17#

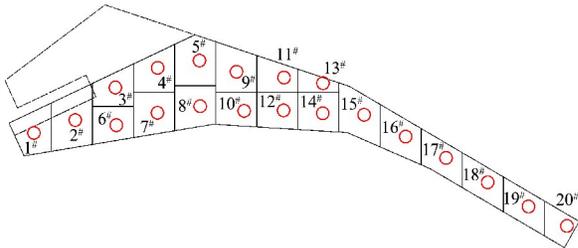


图 3 航道 0.002 5°×0.002 5°网格划分布置  
 Fig. 3 Channel 0.002 5°×0.002 5°grid layout

### 3.2 试验设置

为满足深度学习模型训练对数据密度与结构性的要求,首先对原始数据进行系统性预处理与重构。具体步骤包括:1)异常值剔除与缺区域筛查,确保输入数据质量;2)基于时间与空间权重的联合插值方法,将单区域观测补全为 20 个区域的空间全覆盖数据;3)对所有变量进行归一化处理,统一数据尺度。

在样本构造阶段,采用滑动窗口机制,以连续 6 d 的多变量观测数据作为输入序列,预测未来 1 d 目标变量  $z_t$  的空间分布演化趋势,实现多步时序预测任务。输入数据的形状为  $(T, N, F)$ ,其中  $T$  为时间窗口长度,  $N$  为区域数,  $F$  为输入变量个数。训练集、验证集与测试集按照 7:2:1 的比例划分,并在时间维度上保持不重叠,确保模型评估的独立性和泛化测试的公平性。训练过程采用 Adam 优化器,初始学习率为 0.001,并引入 Early Stopping 机制以防止过拟合。

## 4 结果分析

### 4.1 训练数据

为验证物理机制引导对 LSTM 网络训练效率的影响,记录传统 LSTM 模型与融合物理机制的 PhyLSTM 模型在训练阶段的损失函数收敛过程,见图 4。可以看出,PhyLSTM 模型相较于传统

LSTM 在前 10 轮内收敛更快,初始损失较低,并且始终维持在更低的损失水平,其最终训练误差小于 LSTM,未出现明显过拟合趋势。此外,训练过程中 PhyLSTM 的损失函数收敛更平滑,物理先验的引入有效约束了模型的解空间,引导其朝向物理一致的方向收敛。

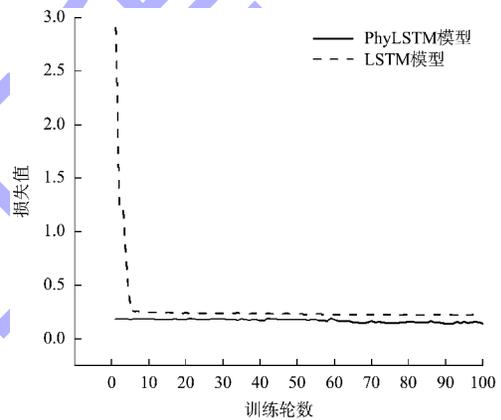


图 4 2 个模型阶段的损失函数收敛过程  
 Fig. 4 Convergence process of loss function in two model stages

### 4.2 结果对比分析

在对全部 20 个网格区域时间序列数据进行回代预测后,对比分析融合物理机制的 PhyLSTM 模型与传统 LSTM 模型的总体预测精度。PhyLSTM 模型在全区预测中的 MAE 为 0.091 5 m, RMSE 为 0.114 5 m, MAPE 为 0.75%,相比之下, LSTM 模型在相同数据集下的 MAE 为 0.145 7 m, RMSE 为 0.163 8 m, MAPE 达 1.18%, PhyLSTM 模型各项指标均明显优于 LSTM 模型。具体而言,以全部 20 个固定区域的实测数据为基准,分别统计其在多项误差指标及预测精度方面的表现,各模型关键性能指标见图 5。绝对误差指标方面,1#区域的 MAE 从 LSTM 模型的 0.122 3 m 降至 PhyLSTM 模型的 0.089 0 m, RMSE 从 0.137 7 m 降

至 0.104 6 m, 误差降低幅度超过 24%。同样地, 3<sup>#</sup>区域的 MAE 和 RMSE 降幅分别达 48%和 37%; 在 MAPE 指标方面, PhyLSTM 同样保持优势: 4<sup>#</sup>和

5<sup>#</sup>区域的 MAPE 分别从 1.24%、1.28% 降至 0.75%、0.76%, 物理机制不仅提升了模型的拟合精度, 也增强了对不同量级区域的泛化适应能力。

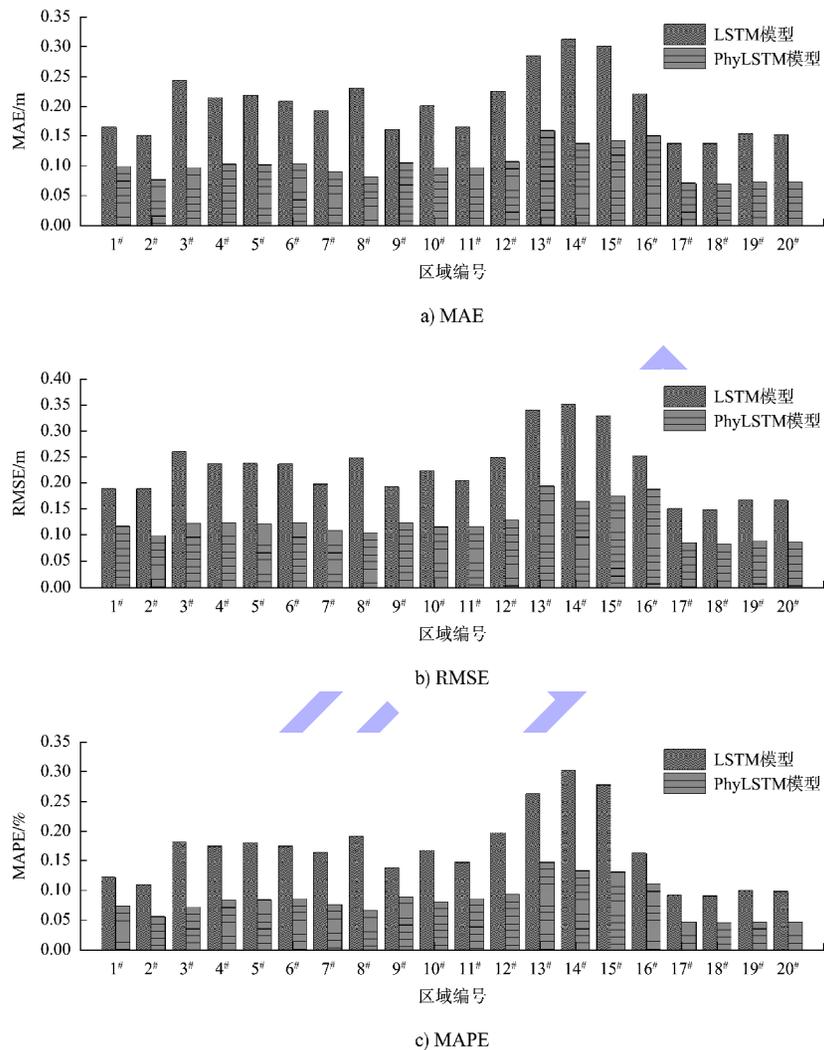


图 5 预测结果关键性能指标

Fig. 5 Key performance indicators of prediction results

此外, 考虑实际工程应用对误差容差的要求, 统计预测误差在 $\pm 0.2$  m 范围内的精确预测区域数量。结果显示, PhyLSTM 模型共有 1 321 个样本 (占总样本数 91.74%) 的预测误差在 $\pm 0.2$  m 范围内, 而 LSTM 模型仅有 1 199 个样本 (占比 83.26%) 达到该精度要求, 融合物理机制后模型对极值与异常变化的适应能力增强。

2024 年 4 月 17 日的港池泥沙淤积预测空间分布结果见图 6。结果表明, 两种模型均能较好地反映港池主要淤积区域的空间特征, 但在淤积强度与局部位置分布上存在差异。从淤积强度来看,

LSTM 模型预测的最大淤积深度为 $-9.66$  m, 集中在港池东南侧, 整体淤积梯度较大。而 PhyLSTM 模型在同一区域的淤积强度分布则更加平滑, 空间过渡更符合实际物理过程; 在淤积位置方面, 两种模型均识别出港池中部及东侧区域 (转角段) 为主要泥沙淤积集中区域, 尤其在  $120.285^{\circ}\text{E}$ — $120.295^{\circ}\text{E}$ 、 $34.306^{\circ}\text{N}$ — $34.310^{\circ}\text{N}$  之间的区域均显示出明显的淤积趋势。LSTM 模型在港池中部出现了局部高估现象, 而 PhyLSTM 模型则更准确地呈现出港池中部至东段由浅至深的淤积梯度, 分布更符合港池实际泥沙运输特征。

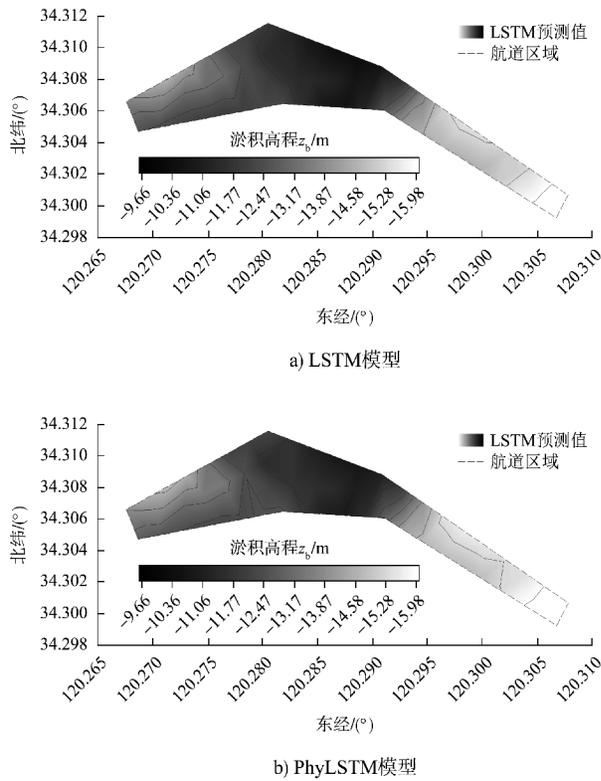
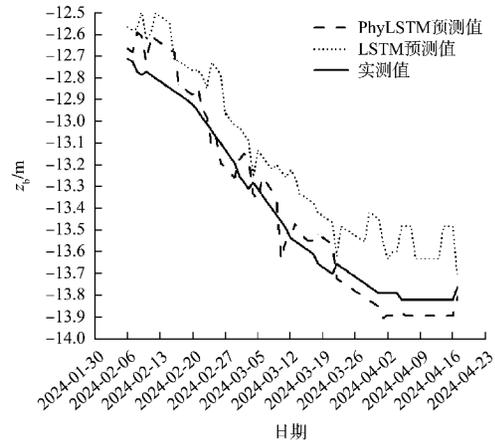


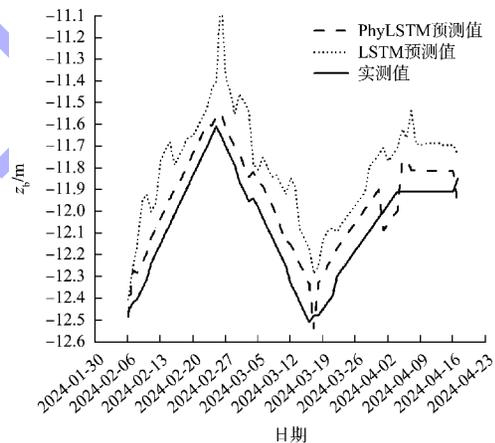
图 6 2024 年 4 月 17 日模型淤积预测结果空间分布  
 Fig. 6 Sedimentation prediction spatial error distribution on April 17, 2024

为进一步分析融合物理机制对预测精度提升的具体作用，选取 6 个典型测点，分别绘制其在研究周期内的淤积高程  $z_b$  变化趋势见图 7。在  $z_b$  呈现明显下降或“V”形变化趋势的时段中， $z_b$  出现极大值或极小值，LSTM 模型往往高估或低估这些极值点，尤其在坡度突变阶段(图 7b) 2024-03-16 和图 7d) 2024-03-21 附近)，PhyLSTM 模型更准确地逼近实测拐点，在处理快速变化区域具有更强的泛化能力和物理一致性。模型对淤积过程的“时间响应准确性”尤为关键，直接影响对突淤时段的识别和疏浚决策制定。LSTM 模型存在预测响应滞后的情况，在多处未能及时反映床面快速变化的拐点时刻；而 PhyLSTM 模型更准确地捕捉了床面高程变化的时间节点，见图 7b) 的 8# 区域，实测床面在 2 月下旬达到最大抬升(约 -11.6 m)，随后迅速下降，而 PhyLSTM 模型在转折点预测上与实测几乎同步，LSTM 模型则出现明显滞后 3~5 d

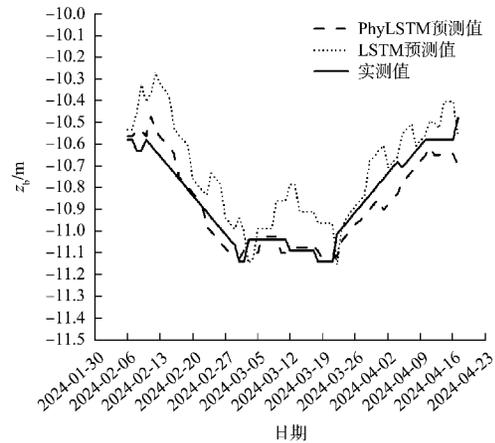
的偏差。此外，由图 7e) 与 f) 可看出，PhyLSTM 对床面下降→回升→再下降的复杂变化过程拟合得更为稳定与平滑，而 LSTM 模型预测则容易产生振荡与平台，影响突变时刻判断。



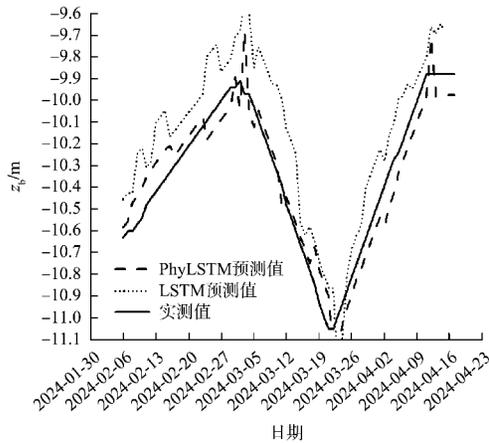
a) 内港池3#区域



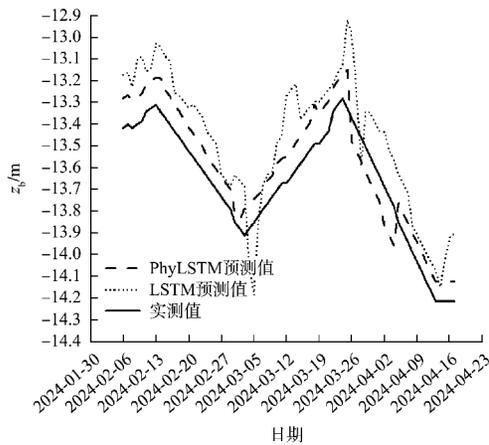
b) 内港池8#区域



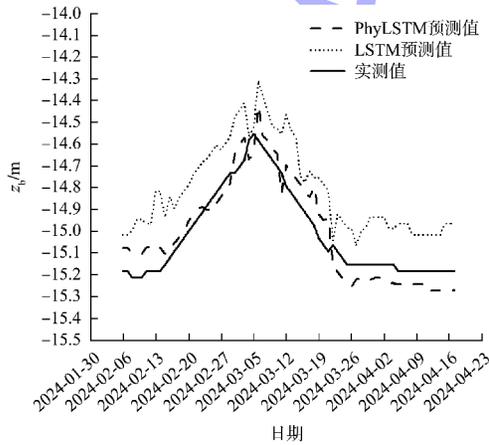
c) 转角段13#区域



d) 转角段14#区域



e) 口门段16#区域



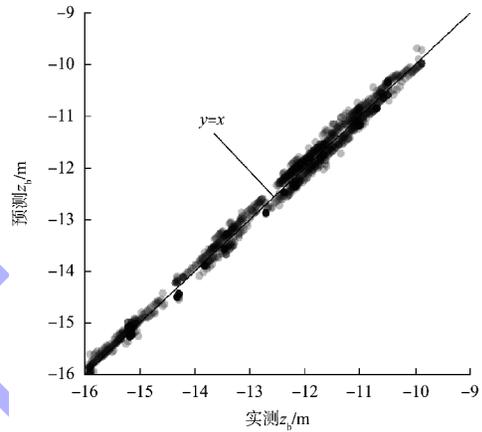
f) 外航道17#区域

图 7 典型淤积区域淤积预测与实测结果对比

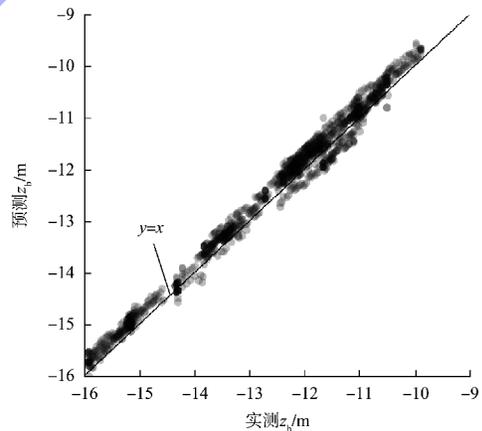
Fig. 7 Comparison of predicted and observed sediment deposition in typical accumulation zones

PhyLSTM 与 LSTM 模型在所有区域上的预测结果与所对应实测值之间的散点分布见图 8, 以  $y=x$

参考线作为理想预测基准, 用于评估模型的拟合精度与偏差分布。可以看出两种模型的散点均集中于  $y=x$  附近, 在全局范围内, 模型都能有效捕捉泥沙淤积高程  $z_0$  的演变趋势, 具有良好的预测能力。由图 8a) 可知, PhyLSTM 模型的偏离度较小, 误差稳定性更强; 由图 8b) 可知, 相比之下, LSTM 模型部分预测区域出现的偏离更明显, 存在相对误差较大的情况。



a) PhyLSTM模型



b) LSTM模型

图 8 航道淤积预测结果对比

Fig. 8 Comparison of prediction results of channel siltation

综上, LSTM 模型在泥沙淤积预测中具有强预测性, 引入物理约束后的 PhyLSTM 模型提升了整体预测精度, 更增强了对关键误差范围的控制能力, 具备更高精度、更强稳定性及更佳极值还原能力, 其预测结果在空间与时间维度上均更具工程适用性。

## 5 结论

1) 本文构建一种融合泥沙动力学知识的物理机制引导型长短期记忆网络(PhyLSTM)模型。该模型结合泥沙运输-扩散与床面演变过程中的关键物理参数,通过引入物理先验模块,引导神经网络有效捕捉泥沙淤积的非线性演化规律。试验结果表明,PhyLSTM在训练阶段收敛速度较传统LSTM模型提高约24%,初始损失降低30%以上,且未出现明显过拟合现象。

2) 基于某典型港池3 a连续监测的1 440组数据(0.002 5°×0.002 5°网格划分),PhyLSTM模型在全区预测中的MAE为0.091 5 m, RMSE为0.114 5 m, MAPE为0.75%,分别较传统LSTM模型降低约37%、30%和36%。预测误差在±0.2 m范围内的样本占比达91.74%,较LSTM模型提升10.18%。验证了该模型在数据稀疏或边界条件复杂场景下的鲁棒性。

3) 在空间分布上,PhyLSTM模型在同一区域的淤积强度分布较LSTM模型预测结果更加平滑,空间过渡更符合实际物理过程;时间序列上,PhyLSTM对快速变化节点(如床面高程突变时段)的响应精度显著提高,避免了LSTM模型常见的预测滞后问题,为港口疏浚决策提供了更及时的依据。

4) 未来可进一步耦合更多环境因子(如潮汐、风场),并拓展至多步时间序列预测场景,以增强模型的普适性与实时性。

### 参考文献:

- [1] 曹祖德,孔令双.粉沙质海岸泥沙运动特性研究[J].海洋学报(中文版),2011,33(5):152-162.  
CAO Z D, KONG L S. Sediment problems of harbor on silt-sandy beach [J]. Acta oceanologica Sinica, 2011, 33(5): 152-162.
- [2] 张钰,张晨.河道型水库库区淤积形态数值模拟研究[J].水科学与工程,2021(3):57-60.  
ZHANG Y, ZHANG C. The study on sedimentation form

- in the reservoir area of Altash Reservoir [J]. Water sciences and engineering technology, 2021(3): 57-60.
- [3] TAMANG S K, SONG W J, FANG X, et al. Framework for quantifying flow and sediment yield to diagnose and solve the aggradation problem of an ungauged catchment [J]. Proceedings of the International Association of Hydrological Sciences, 2018, 379: 131-138.
- [4] 朱沈鸣,史英标,程文龙.钱塘江河口段含沙量变化特征模拟分析[J].水电能源科学,2024,42(1):69-73.  
ZHU S M, SHI Y B, CHENG W L. Simulation analysis of sediment concentration variation in the Qiantang Estuarine reach [J]. Water resources and power, 2024, 42(1): 69-73.
- [5] 张磊,余小建,马进荣.茅尾海航道开发潮流物理模型试验研究[J].水运工程,2017(12):64-70.  
ZHANG L, SHE X J, MA J R. Tidal current experimental study on waterway development in Maowei Hai sea [J]. Port & waterway engineering, 2017(12): 64-70.
- [6] 荆一戈,季则舟,张金凤,等.考虑群桩影响的高桩码头冲淤数值模拟研究:以天津港为例[J].水运工程,2025(6):44-54.  
JING Y G, JI Z Z, ZHANG J F, et al. Numerical simulation study on sediment transport of high-pile wharf considering influence of pile group: a case study of Tianjin Port [J]. Port & waterway engineering, 2025(6): 44-54.
- [7] GOVINDARAJU R S. Artificial neural networks in hydrology II: hydrologic applications [J]. Journal of hydrologic engineering, 2000, 5(2): 124-137.
- [8] KAVEH K, KAVEH H, BUI M D, et al. Long short-term memory for predicting daily suspended sediment concentration [J]. Engineering with computers, 2021, 37: 2013-2027.
- [9] 香天元,孙思瑞,王超,等.鄱阳湖流域水沙变化及出湖水沙模拟研究[J].人民长江,2024,55(3):97-104.  
XIANG T Y, SUN S R, WANG C, et al. Study on water-sediment variation in Poyang Lake Basin and simulation of water-sediment out of lake [J]. Yangtze River, 2024, 55(3): 97-104.