

DOI:10.3876/j.issn.1000-1980.2025.05.011

基于内嵌物理信息神经网络的复式河道 非恒定水动力过程求解方法

肖 洋^{1,2,3,4,5}, 陆钰涵^{1,2}, 刘佳明^{1,4,6}, 许 栋^{1,2,4}

(1. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098; 2. 河海大学水利水电学院, 江苏 南京 210098;
3. 河海大学长江保护与绿色发展研究院, 江苏 南京 210098;
4. 河海大学水利部水循环与水动力系统重点实验室, 江苏 南京 210098;
5. 苏州科技大学建筑与城市规划学院, 江苏 苏州 215009; 6. 河海大学港口海岸与近海工程学院, 江苏 南京 210098)

摘要: 为提升复式河道非恒定水动力过程的模拟精度, 提出了一种基于物理信息神经网络(PINN)的复式河道非恒定流模拟方法, 该方法将圣维南方程和 1D+模型的物理约束融入深度学习框架, 构建用于模拟洪峰与风暴潮叠加情形的 PINN 模型, 同时设计了由矩形河道向复式河道迁移的迁移学习策略, 开发了结合 Adam 和 SGD 的双优化器训练方法。算例验证结果表明: 所提出的 PINN 模型能有效捕捉滩槽水力交互特性, 相比传统方法预测精度提升 31.8% (RMSE 从 0.085 m 降至 0.058 m); 基于矩形河道预训练的迁移学习策略能显著提升模型性能, RMSE 降低 34.5%; Adam+SGD 双优化器训练策略有效抑制了过拟合现象, 使模型预测精度提升 32.5%。

关键词: 复式河道; 深度学习; 圣维南方程; 非恒定流; PINN

中图分类号: TV133

文献标志码: A

文章编号: 1000-1980(2025)05-0090-10

A method for solving unsteady hydrodynamic processes in compound river channels based on embedded physical information neural networks

XIAO Yang^{1,2,3,4,5}, LU Yuhuan^{1,2}, LIU Jiaming^{1,4,6}, XU Dong^{1,2,4}

(1. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China;

2. College of Water Conservancy & Hydropower Engineering, Hohai University, Nanjing 210098, China;

3. Yangtze Institute for Conservation and Development, Hohai University, Nanjing 210098, China;

4. Key Laboratory of Water Cycle and Hydrodynamic System, Ministry of Water Resources, Hohai University, Nanjing 210098, China;

5. School of Architecture and Urban Planning, Suzhou University of Science and Technology, Suzhou 215009, China;

6. College of Harbour, Coastal and Offshore Engineering, Hohai University, Nanjing 210098, China)

Abstract: To improve the accuracy of simulating unsteady hydrodynamic processes in compound river channels, a method for simulating unsteady flows in compound river channels based on physics-informed neural networks (PINNs) was proposed. The Saint-Venant equations and the 1D+ model were incorporated as physical constraints into the deep learning framework to construct a PINN model for simulating compound scenarios with overlapping flood peaks and storm surges. In addition, a transfer learning strategy was designed to achieve migration from rectangular river channels to compound river channels, and a dual-optimizer training scheme combining Adam and SGD was developed. The verification results of the example show that the proposed PINN model can effectively capture the hydraulic interactions between the river channel and floodplain, with a 31.8% improvement in prediction accuracy compared to traditional methods (RMSE is reduced from 0.085 m to 0.058 m). The transfer learning strategy based on pretraining in rectangular river channels can significantly improve the model performance, with the RMSE reduced by 34.5%; the training strategy using both Adam and SGD optimizers effectively suppresses overfitting, increasing the model's prediction accuracy by 32.5%.

基金项目: 国家自然科学基金长江联合基金项目(U2240209); 国家自然科学基金面上项目(52379075); 水利部重大科技项目(SKS-2022124)

作者简介: 肖洋(1974—), 男, 教授, 博士, 主要从事水力学及河流动力学研究。E-mail: Sediment_lab@hhu.edu.cn

引用本文: 肖洋, 陆钰涵, 刘佳明, 等. 基于内嵌物理信息神经网络的复式河道非恒定水动力过程求解方法[J]. 河海大学学报(自然科学版), 2025, 53(5): 90-99.

XIAO Yang, LU Yuhuan, LIU Jiaming, et al. A method for solving unsteady hydrodynamic processes in compound river channels based on embedded physical information neural networks[J]. Journal of Hohai University(Natural Sciences), 2025, 53(5): 90-99.

Key words: compound river channel; deep learning; Saint-Venant equation; unsteady flow; PINN

洪水过程是河流复式河道生态系统中最显著的自然扰动,是复式河道滩槽能量、物质交换和滩槽生态系统演化的主要驱动力^[1-2]。风暴潮同样是影响河口及感潮河段的重要因素,它是一种由于大气扰动和热带气旋引起气压剧变而引发海面异常升降的现象^[3],可以显著改变河道水位与流速分布。由于河流的非恒定特征,复式河道水位、流场等水力要素变化剧烈,水力特性十分复杂。因此,研究复式河道非恒定流水动力过程具有重要的科学意义。

国内外学者采用理论分析、试验研究和数值模拟等方法对复式河道非恒定流水动力过程开展了较多研究:Zheleznyakov^[4]描述了随时间变化的水力流动参数与河床演变之间的关系,探讨了运河断面形态与土壤条件之间的关联;Wormleaton 等^[5]通过数据分析发现,采用单一河道断面法计算过流能力将导致计算流量偏小,若忽略滩槽间动量交换采用简单断面分割法,将使计算流量偏大;Knight 等^[6]针对复式河段滩槽交界面表观剪切应力与床面剪切应力、相对水深和相对宽度开展研究,总结了表观切应力随相对水深和相对宽度变化的经验公式;Proust 等^[7]使用独立小节法(independent subsections method,ISM)和圣维南方程(Saint-Venant Equations,SVE)耦合的计算方法求解了主槽和滩地的动量守恒方程;Kaddi 等^[8]发展了适用于复式河道非恒定流的 1D+模型;Liu 等^[9]通过二维/三维数值模型,研究了非恒定流对复式河道水动力过程的影响,发现水位波动幅度与综合流量,平均水位与平均流量之间存在正相关关系;汪昊燃等^[10-11]通过耦合水文和水力学模型,对秦淮河流域洪水进行了模拟;汪晨辉等^[12]基 RSM 紊流模型研究了含滩地交汇的河道水动力特性与掺混特征。

近年来,机器学习在水动力模拟领域展现出巨大潜力。以人工神经网络(artificial neural network,ANN)、支持向量机(support vector machine,SVM)和长短期记忆网络(long short-term memory,LSTM)为代表的深度学习方法,在流量预测和水位模拟中取得了显著成果。然而,数据驱动方法往往忽视了物理规律的约束,在数据稀疏区域的预测可靠性有待提高。基于内嵌物理信息神经网络(physics-informed neural networks,PINN)^[13-15],通过将偏微分方程约束融入深度学习框架弥补了传统机器学习方法缺乏物理可解释性、训练需求量大等问题,已被应用于流体力学的研究中^[16-18]。例如:Feng 等^[19]通过求解圣维南方程组,模拟了潮汐和风暴潮条件下矩形河道中洪水波的传播过程;方卫华等^[20]提出一种基于 PINNs 的圣维南方程组数据同化方法,模拟了矩形河道中非恒定流;袁赛瑜等^[21]提出知识数据双驱动的感潮河网水动力智能模拟方法,并应用于感潮河网案例的水动力模拟中。然而,还未见 PINN 在复式河道非恒定流模拟中的应用,如何将 PINN 应用于复式河道非恒定流过程的模拟,有效处理滩槽水力动态交互和复杂边界条件,并优化 PINN 的计算是值得探究的问题。

为探究 PINN 能否适用于复式河道非恒定水动力过程模拟,本文构建了融合圣维南方程和 1D+模型的 PINN 模型,提出由矩形河道迁移至复式河道的迁移学习训练策略,开发了 Adam+SGD 双优化器训练方法,并通过多组洪水和风暴潮算例对所提方法的有效性和实用性进行了验证。

1 模型构建与求解方法

1.1 非恒定流控制方程

矩形河道(图 1(a))一维非恒定流的水动力学过程可用圣维南方程组描述。该方程组由连续方程(式(1))和动量方程(式(2))组成,体现了水流运动的质量和动量守恒特性。

$$\frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = q \tag{1}$$

$$\frac{\partial Q}{\partial t} + \frac{\partial}{\partial x}\left(\frac{Q^2}{A}\right) + gA \frac{\partial Z}{\partial x} + g \frac{n^2 |u|}{R^{\frac{4}{3}}} Q = 0 \tag{2}$$

其中

$$R = bh/(2h + b)$$

式中: x,t 分别为空间坐标和时间坐标; A 为过水断面面积; Q 为流量; u 为断面平均流速; q 为单位长度的侧向入流量,主要包括地表径流、地下径流、地下水入渗和降雨等水量补给; Z 为河道水位; g 为重力加速度,取 9.81 m/s^2 ; n 为曼宁系数; R 为水力半径; h 为河道水深; b 为河道宽度。




图1 河道断面示意图

Fig. 1 River channel cross-section

复式河道(图 1(b))由主槽和滩地构成,其水力特性较矩形河道更复杂^[22-23],主要表现为:①滩槽间存在显著的流速差异;②存在强烈的横向动量交换;③水流结构随水位变化而改变。为准确描述这些特征,采用基于独立小节法的 1D+模型^[8]的控制方程:

$$\frac{\partial A}{\partial t} + \frac{\partial (Q_m + Q_f)}{\partial x} = 0 \tag{3}$$

$$\frac{\partial Q_m}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q_m^2}{A_m} \right) + g A_m \frac{\partial Z}{\partial x} = -g A_m J_m - \frac{\tau_{int} h_f}{\rho} + u_{int} q_{ex} \tag{4}$$

$$\frac{\partial Q_f}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q_f^2}{A_f} \right) + g A_f \frac{\partial Z}{\partial x} = -g A_f J_f + \frac{\tau_{int} h_f}{\rho} - u_{int} q_{ex} \tag{5}$$

其中

$$q = \frac{\partial A_f}{\partial t} + \frac{\partial Q_f}{\partial x}$$

式中: Q_m 、 Q_f 分别为主槽、滩地的流量; A_m 、 A_f 分别为主槽、滩地的过水断面面积; J_m 、 J_f 分别为主槽、滩地的水头损失梯度; u_{int} 为滩槽交界处将水流方向上的速度沿水深方向进行积分平均后的流速; τ_{int} 为滩槽交界处的横向雷诺应力; h_f 为滩地水深; q_{ex} 为单位长度滩槽水流交换量(以主槽流向滩地为正); ρ 为水的密度,取 1000 kg/m^3 。

为了使方程组闭合,需要对 u_{int} 和 τ_{int} 进行假设。Proust 等^[24]将 u_{int} 视为主槽平均流速 u_m 和滩地平均流速 u_f 的函数:

$$u_{int} = \varphi u_m + (1 - \varphi) u_f \tag{6}$$

式中 φ 为权重,取 $0.3^{[8]}$ 。

Kaddi 等^[8]使用基于交换流量模型^[25](exchange discharge model, EDM)的混合长度模型计算 τ_{int} :

$$\tau_{int} = \rho \psi (u_m - u_f)^2 \tag{7}$$

式中 ψ 为湍流交换系数,取 $0.02^{[8]}$ 。

1.2 基于物理约束的深度学习模型

1.2.1 模型架构与损失函数设计

传统的人工神经网络模型通过最小化预测结果与真实数据之间的损失函数,在大量标注数据的驱动下,利用反向传播算法迭代更新网络参数,从而实现模型的训练和优化。然而,由于缺乏物理规律的约束,导致其在物理可解释性、泛化能力及对少样本问题的适应性方面存在明显不足。若将物理方程嵌入损失函数,通过计算输出对应的方程残差参与训练,不仅能在缺乏数据的位置指导网络学习,还能保证结果符合物理规律,提升模型的可解释性。据此,给出融合圣维南方程组的 PINN 框架(图 2, ε 为误差允许值)。PINN 以 x 和 t 为输入,以平均流速 u 和河道水深 h 为输出,主干部分为人工神经网络,计算损失函数时嵌入物理方程,从而约束人工神经网络的预测结果。即,模型的损失函数由数据驱动损失 L_u 和物理模型驱动损失 L_r 组成:

$$L = \lambda_u L_u + \lambda_r L_r \tag{8}$$

其中

$$L_u = \frac{1}{N_u} \sum_{i=1}^{N_u} |u_N(t_{ui}, x_{ui}) - u_i|^2 \quad L_r = \frac{1}{N_r} \sum_{j=1}^{N_r} |r(t_{rj}, x_{rj})|^2$$

式中: λ_u 、 λ_r 分别为数据驱动损失和物理模型驱动损失的权重系数,用于调节损失项对训练的相对影响,采用自适应权重策略计算; $u_N(t_{ui}, x_{ui})$ 为逼近函数 $u(t, x)$ 的神经网络; $r(t_{rj}, x_{rj})$ 为偏微分方程的残差; t_{ui} 、 x_{ui} 、 u_i

分别为第 i 个训练样本的时间坐标、空间坐标和观测值; N_u 为已知数据点数量; t_{ij} 、 x_{ij} 分别为第 j 个配点的时间坐标和空间坐标; N_r 为配点数量。 L_u 表达式中, $\{t_{ui}, x_{ui}, u_i\}_{i=1}^{N_u}$ 表示通过初始条件和边界条件获取的训练数据, 包括试验观测、数值仿真等手段获取的训练数据, 其中。 L_r 表达式中, $\{t_{rj}, x_{rj}\}_{j=1}^{N_r}$ 表示方程的训练配点, 由于自动微分技术可以高效获取方程残差 $r(t_{ij}, x_{ij})$, 因此这部分损失函数在训练时不需要额外的标签数据。




图 2 融合圣维南方程组的 PINN 框架

Fig. 2 PINN framework incorporating Saint-Venant equations

试验发现,在捕捉复杂非线性特征时网络深度对结果影响较大,在工况较复杂的情况下应选择更深的网络以增强表达能力。因此,为了兼顾模型的精确性和训练效率,本文根据工况计算的复杂程度,灵活选用 3 层或 5 层中间层,每层 64 个神经元。神经网络的激活函数选用 tanh。

1.2.2 数据集准备

参考 Feng 等^[19]的试验设计了 5 组工况:基准工况(工况 1 和工况 2)、复杂边界工况(工况 3 和工况 4)和迁移工况(工况 5)。河道长 305 m,宽 3 m(主槽宽 1.5 m、滩地宽 1.5 m),河道糙率设定为 0.015,坡度设置为 0.007,无旁侧入流。工况设置和边界条件见表 1 和图 3。复式河道模型以 1D+模型为物理约束,矩形河道模型以 SVE 为物理约束。为模拟实际观测条件,在 $x = 100, 200$ m 处设置监测断面,并按照 USGS 水位测量标准添加 $\pm 0.2\%$ 的随机噪声。

表 1 工况设置

Table 1 Operating condition setup

工况	河道类型	上游边界条件	下游边界条件
1	矩形河道	设为恒定流量, $Q=5.7\text{ m}^3/\text{s}$	施加风暴潮,周期 50 h 振幅 2.4 m 的正弦波,即水深 $h = 2.4\sin\left(\frac{2\pi t}{50}\right)$ $0 \leq t \leq 24$
2	复式河道	设为恒定流量, $Q=5.7\text{ m}^3/\text{s}$	施加风暴潮,周期 50 h 振幅 2.4 m 的正弦波,即水深 $h = 2.4\sin\left(\frac{2\pi t}{50}\right)$ $0 \leq t \leq 24$
3	复式河道	设为恒定流量, $Q=5.7\text{ m}^3/\text{s}$	施加潮汐信号 h_1 ,并在 t_0 时叠加风暴潮 h_2 影响, $h_1 = 1.5\sin\left(\frac{2\pi t}{25}\right)$ $0 \leq t \leq 240$ $h_2 = 2.4\sin\left(\frac{2\pi t}{50}\right)$ $t_0 \leq t \leq t_0 + 48$
4	复式河道	施加随时间变化的流量 $Q = 17 + 11.3\sin\left(\frac{2\pi t}{480}\right)\text{ m}^3/\text{s}$ $0 \leq t \leq 240$	正常水深边界,坡度 $S=0.001$
5	复式河道	设为恒定流量 $Q=5.7\text{ m}^3/\text{s}$	施加风暴潮,周期 50 h 振幅 2.4 m 的正弦波, $h = 2.4\sin\left(\frac{2\pi t}{50}\right)$ $0 \leq t \leq 24$

注: h 的单位为 m; t 的单位为 h。

1.2.3 模型训练与优化策略

为了兼顾训练效率和计算精度,初始学习率统一设置为 1×10^{-4} ,且采用指数衰减策略,即每训练 10 000 步,学习率按 0.95 的衰减率逐步减小。这种衰减策略能够在训练初期保持较快的收敛速度,帮助模型迅速接近最优解;而在训练后期,逐步降低学习率,能够避免过大更新步长而引发的震荡,保证模型的稳定性与收敛性。此外,采用 Xavier 方法^[26]初始化权重,并将初始偏置设为 0。模型的训练流程如图 4 所示。

为了寻找 PINN 的最佳优化策略和数据迁移影响,以工况 1 和工况 2 为例,分别用 Adam 优化器、Adam+L-BFGS 优化器、Adam+SGD 优化器 3 种优化策略,训练矩形河道、复式河道工况下的基准模型。

Adam 优化器是一种结合了动量法和 RMSProp 的优化算法,通过同时考虑梯度的一阶动量(均值)和二阶动量(方差),动态调整学习率,使得每次参数更新过程更加高效和稳定,具有更快的收敛速度,且适用于处理噪声较大的数据集和稀疏梯度问题。因此,Adam 优化器经常应用于河道水流过程智能模型中^[24-25]。L-BFGS 优化器是一种常用于大规模问题的优化算法,属于准牛顿方法。核心思想是利用有限的历史梯度和参数更新信息,构造出 Hessian 矩阵(即二阶导数矩阵)逆的近似,但不需要存储完整的 Hessian 矩阵,这大大减少了存储和计算的复杂度。Rathore 等^[27]提出了 Adam+L-BFGS 双优化器组合,显著提高了 PINN 性能。

SGD 优化器是机器学习和深度学习中常用的优化算法。它在每次迭代中随机选取一部分数据来计算梯度,从而更新模型参数。与传统的批量梯度下降不同,SGD 由于使用小批量样本计算梯度,能够更快地更新参数,减少计算开销,适合大规模数据集的训练。Keskar 等^[28]研究了 Adam+SGD 组合的优化器,证明该算法兼顾了收敛效率和计算稳定性。

为确保优化器切换的平滑性与有效性,先通过预试验确定 Adam 优化器的最优训练轮次,即达到最小均方根相对误差与均方根误差所需的最小迭代次数。当训练误差下降速率显著减缓,或误差收敛至预设阈值时,标记该训练节点,正式试验时在该节点处切换为 L-BFGS 优化器或 SGD 优化器,继续训练直至整体损失函数稳定收敛。

硬件配置方面,采用的 CPU 为 Intel i7-13700K 处理器,GPU 为 NVIDIA RTX 4070。

1.3 迁移学习方法

迁移学习增强的 PINN 可以加速模型的收敛过程,减少计算资源的消耗^[29],进一步提高模型的泛化能力^[30]。首先在较为简单的矩形河道上训练模型,获得源模型的网络参数 θ_s :

$$\theta_s = \{w_s^{(1)}, b_s^{(1)}, w_s^{(2)}, b_s^{(2)}, \dots, w_s^{(n_s)}, b_s^{(n_s)}\}$$

(9)

式中: $w_s^{(i_s)}$ 、 $b_s^{(i_s)}$ 分别为源模型第 i_s 层隐藏层上的权重和偏置, $i_s = 1, 2, \dots, n_s$; n_s 为源模型隐藏层层数。

随后,将式(9)隐藏层的权重和偏置参数迁移至目标模型中。目标模型用于模拟复式河道上的非恒定流动,其网络结构与源模型保持一致,仅输出层根据任务需求进行调整。目标模型的网络参数 θ_t 为

$$\theta_t = \{w_t^{(1)}, b_t^{(1)}, w_t^{(2)}, b_t^{(2)}, \dots, w_t^{(n_t)}, b_t^{(n_t)}\}$$

(10)

式中: $w_t^{(i_t)}$ 和 $b_t^{(i_t)}$ 分别为目标模型第 i_t 层隐藏层的权重和偏置, $i_t = 1, 2, \dots, n_t$; n_t 为目标模型隐藏层层数。有 $w_t^{(i_t)} = w_s^{(i_s)}$, $b_t^{(i_t)} = b_s^{(i_s)}$,即将源模型的权重和偏置直接迁移到目标模型的对应层。

由于目标任务涉及更多水动力学变量,在目标模型导入权重、偏置参数后输出通道由 2 通道扩展至 4 通道,输出层参数需重新初始化。在迁移完成后,采用全参数微调策略(fine-tuning),以源模型参数作为初始值,对目标模型的所有网络层进行再训练,从而提升模型对复杂水力特征的适应能力。在训练过程中,损失函数保持与源模型一致,仍由数据驱动损失和物理模型驱动损失组成。




图 3 上下游边界条件

Fig. 3 Upstream and downstream boundary conditions




图 4 PINN 训练流程

Fig. 4 PINN training process

1.4 模型评价指标

为了量化模型预测性能,采用均方根相对误差 (root mean square relative error, RMSRE) 和均方根误差 (root mean squared error, RMSE) 这 2 种常用的误差评估指标对模型进行评价。

2 模型验证与分析

2.1 模型性能评估与验证

为系统评估所提方法的有效性,首先采用工况 1 和 2 验证模型的基本性能,然后通过工况 3 和 4 测试模型对复杂边界条件的适应能力,最后基于工况 5 分析迁移学习策略的效果。

各模型的网络配置和评价指标见表 2。基准工况中,复式河道模型的 RMSE 和 RMSRE 均优于矩形河道模型,表明所提出的 1D+物理约束能有效提升预测精度 (RMSRE、RMSE 分别降低 31.4%、31.8%)。在复杂工况 (工况 3 和工况 4) 下,尽管预测难度增加,模型仍保持了较好的性能, RMSE 控制在 0.08 m 以内,显示出较强的泛化能力。

PINN 以 Feng 等^[19] 的试验流速和水深数据为真实值进行评价。从空间维度看,矩形河道模型 (图 5(a)) 在河道 $x=0\sim100\text{ m}$ 位置处存在红色峰值区域,模型的正误差 (误差为真实值减去预测值) 约为 0.08 m,在 $x=100\sim200\text{ m}$ 位置处存在蓝色峰值区域,模型存在 -0.05 m 左右的负误差,这种正负误差的交替现象表明,模型在拟合过程中存在一定的振荡性,可能受到边界条件设置或网络训练收敛性的影响,导致预测值在某些区域系统性地高于或低于真实值。复式河道模型的误差分布更为均匀 (图 5(b)), 且误差绝对值在 0.01 m 以内,两者的对比说明在考虑河道断面复杂结构后, PINN 能够更准确地捕捉水面线的变化特征,提升了对非恒定流动的拟合能力。

表 2 各工况的神经网络配置及误差评价结果

Table 2 Neural network configurations and error evaluation results for each working condition

工况	神经网络配置			RMSRE	RMSE/m
	输入层/层	中间层/层	输出层/层		
1	2	3	2	0.010 5	0.085
2	2	3	4	0.007 2	0.058
3	2	5	4	0.014 9	0.066
4	2	5	4	0.023 1	0.079
5	2	3	4	0.004 6	0.038




图 5 PINN 水深预测值与真实值误差

Fig. 5 Error between PINN water depth prediction and true value

相较于工况 1 和工况 2,工况 3 和工况 4 具有更长的模拟时长和更复杂的边界条件。工况 3 考察了持续波动的水位对模型预测精度的影响 (图 5(c))。从时间维度看,预测误差具有周期性规律,误差极值主要存在水位波动的峰值和谷底之间;从空间维度看,误差集中分布于河道末端,且在 $x=100,200\text{ m}$ 位置分别有正负误差峰值,这与工况 1 和工况 2 的表现一致。工况 4 考察了长周期的流量变化对模型预测精度的影响,结

果如图 5(d) 所示。工况 4 的误差分布与工况 2 类似,在 $x=0\text{ m}$ 处存在负误差区域。与工况 2 不同的是,工况 4 在 $x=0\text{ m}$ 的负误差逐渐向下游蔓延至 $x=100\text{ m}$ 处,且误差极值更大,这说明长周期边界波动会在模型中形成更强的累积效应,导致局部区域误差显著扩大。在 $x=150\sim 200\text{ m}$,误差出现一定的正误差区域,但是在 $x=200\text{ m}$ 后误差显著降低,这说明 PINN 在靠近观测断面($x=200\text{ m}$)处能够有效利用测站数据对预测结果进行校正,从而提高该位置的预测精度。

总体来说,与工况 1 的矩形河道模型相比,工况 2 中引入复式河道断面结构后,PINN 的预测精度显著提升,表现出更好的空间误差均匀性和更小的误差幅度,说明模型在考虑断面复杂性后对非恒定流动过程的拟合能力有所增强。工况 3 与工况 4 进一步验证了模型在应对长时序模拟和复杂边界扰动(如持续波动水位与长周期流量变化)方面的鲁棒性。尽管在无监测数据约束区域存在一定系统性误差,但整体误差保持在可接受范围内,且在接近观测断面处表现出较好的校正能力,表明 PINN 不仅具备良好的空间泛化能力,还能在复杂水动力边界条件下保持预测稳定性,具有较强的工程应用潜力。

2.2 迁移学习效果

为了研究 PINN 的迁移学习,将工况 1 的矩形河道模型训练结果迁移到工况 2 的复式河道模型中,建立工况 5。由图 6 可知,从零开始训练的模型在迭代约 4000 次后误差迅速降低,而迁移学习模型在迭代 16000 次后,误差才逐步减小。这是由于源任务与目标任务之间存在一定差异,迁移学习策略需要额外的调优和训练,以适应目标任务的特定特征,因此迁移学习策略在初始阶段的收敛速度较慢,模型的预热时间更长。然而,在训练后期,当迭代次数超过 32000 次后,迁移学习模型的精度实现了反超。

由表 2 可知,工况 5 的 RMSRE 和 RMSE 分别为 0.004 6 和 0.038 m,优于工况 2 的 0.007 2 和 0.058 m (降低了 34.5%),表明虽然迁移学习在初期的收敛速度较慢,但在经过充分的调优和训练后,模型利用源任务中的知识显著提高对目标任务的预测能力。尽管在预见期 $t<2\text{ h}$ 和 $t>22\text{ h}$ 的河道末端区域($x=200\sim 300\text{ m}$,图 5),3 种模型均表现出一定的正误差或负误差,但迁移学习模型在误差幅度上明显更小。

综上可知,迁移学习策略在训练过程中需要经历初期的适应期,随着迭代的深入,迁移学习能够有效利用已有模型的知识,优化训练过程,其长远效果往往优于从零开始训练的模型。PINN 的迁移学习模型具有更优的预测精度和泛化能力。

2.3 优化策略对模型性能的影响

通过对比分析 3 种优化策略(Adam、Adam+L-BFGS、Adam+SGD)在工况 1 和工况 2 上的训练结果(图 7),可以评估不同优化策略的性能。其中,在图 7(b)(c)(e)(f)上添加了黑色竖虚线,用来标示优化器的切换,虚线两侧分别代表不同优化策略应用的训练阶段。

Adam+SGD 优化器表现最佳,其次是 Adam+L-BFGS 优化器,而单独的 Adam 优化器效果较差。由图 7(a)和(d)可知,Adam 优化器在工况 1 和工况 2 的误差曲线有着相似的趋势:在训练前期误差较为稳定,中期有一个较大下降,达到最优训练次数后误差缓慢回升。以工况 2 复式河道模型为例,当迭代次数达到 47000 次时,Adam 优化器的 RMSE 达到极小值,继续训练则出现过拟合现象,RMSE 缓慢上升至 0.241 m。若在 47000 次迭代时,将 Adam 优化器的训练结果放入 L-BFGS 或 SGD 优化器中继续训练,则可以有效避免过拟合,并提高模型的精度。由图 7(e)(f)可知,2 种优化策略对应的 RMSE 分别稳定在 0.130 m 和 0.058 m,各减少了 46.1%和 75.9%。在矩形河道模型中,3 种优化策略的表现与复式河道类似,Adam 优化器在某次迭代中达到极小值后出现过拟合,若采用双优化器策略则可以避免过拟合的发生。Adam+L-BFGS 优化器和 Adam+SGD 优化器对应的 RMSE 分别稳定在 0.091 6 m 和 0.085 2 m,减少了 27.4%和 32.5%。由此可见,在矩形河道工况和复式河道的基准工况中,训练过程中结合不同优化器能够提高模型的整体性能。

由图 8 可知,双优化器在整体上的表现均优于 Adam 优化器,尤其是针对复杂的工况(复式河道模型),表现出更优越的性能。以评价指标差异较大的 4 h 预见期为例,2 个工况下 Adam 优化器的 RMSRE 分别为




图 6 工况 2 和工况 5 的模型预测误差与迭代次数关系

Fig. 6 Relationship between model prediction error and iteration number for working conditions 2 and 5




图 7 不同优化策略下模型误差与迭代次数关系

Fig. 7 Relationship between model error and iteration number under different optimization strategies




图 8 不同优化策略评价指标雷达图

Fig. 8 Radar chart of evaluation metrics under different optimization strategies

0.107 和 0.017,而对应的 Adam+L-BFGS 优化器为 0.039 和 0.014,Adam+SGD 优化器为 0.007 和 0.010,这说明 Adam+SGD 优化器的性能更高。这一结果表明,所提出的双优化器策略能有效平衡模型的收敛速度和泛化性能。

2.4 模型的局限性

尽管本文提出的模型取得了良好效果,但仍存在一定局限。由于计算机算力限制,本文仅考虑一维水动力约束,未能表达二维或三维水动力特征。未来研究可以构建高效准确的降阶模型(reduced-order model, ROM),在降低模型复杂度、提升计算效率的同时,近似描述高维系统。此外,尽管本文模型在一定程度上减少了对大量观测数据的依赖,其性能仍受限于输入数据的质量和空间分布。值得指出的是,本文提出的 PINN 框架具备良好的可扩展性,未来随着典型案例库的持续积累,融合现场感知、数模模拟与实测资料的多源数据体系将有助于解决数据稀疏和不均匀的问题。

3 结 论

- a. 复式河道 PINN 通过融合 1D+模型物理约束,考虑了滩槽水力交互特性。在基准工况验证中,模型预测精度优于传统矩形河道模型, RMSE 和 RMSRE 分别降低了 31.8% 和 31.4%。在复杂边界工况下,模型仍保持较好性能(RMSE<0.08 m),展现出较强的适应性。
- b. 基于矩形河道预训练的知识迁移策略展现出良好效果。虽然在训练初期收敛较慢,但最终预测精度显著提升, RMSE 较直接训练降低了 34.5%。该策略充分利用了不同河道水动力特性的相似性,为提高模型训练效率提供了新思路。
- c. 双优化器训练策略(Adam+SGD)显著提升了模型性能。相比单一 Adam 优化器,该策略有效抑制了过拟合现象,将 RMSE 从 0.241m 降至 0.058 m,降幅达 75.9%。特别是在 4 h 预见期内,预测精度提升最为显著,为实际应用提供了可靠保障。
- d. 构建的 PINN 模型能够有效利用测站数据对预测结果进行校正,从而提高该位置的预测精度。

参考文献:

[1] 钟娜. 复式河道一维数值模拟[D]. 南京:河海大学,2007.

[2] 颜仁聪. 复式河道一维水力计算方法研究及应用:以桑布尔河为例[D]. 扬州:扬州大学,2022.

[3] 罗锋,汪忆,杨洁,等. 相似路径台风风暴潮过程对比[J]. 河海大学学报(自然科学版),2023,51(6):130-140. (LUO Feng, WANG Yi, YANG Jie, et al. Comparative study on storm surge processes caused by typhoons with similar tracks[J]. Journal of Hohai University (Natural Sciences), 2023, 51(6): 130-140. (in Chinese))

[4] ZHELEZNYAKOV G V , RZHANITSYN N A , IBAD-ZADE Y A , et al. Research on the morphology of river beds and their modelling[J]. Hydrotechnical Construction, 1971, 5(3): 285-288.

[5] WORMLEATON P R, ALLEN J, HADJIPANOS P. Discharge assessment in compound channel flow[J]. American Society of Civil Engineers, 1982, 108(9): 975-994.

[6] KNIGHT D W, DEMETRIOU J D. Flood plain and main channel flow interaction[J]. Journal of Hydraulic Engineering, 1983, 109(8): 1073-1092.

[7] PROUST S, BOUSMAR D, RIVIERE N, et al. Nonuniform flow in compound channel: a 1-D method for assessing water level and discharge distribution[J]. Water Resources Research, 2009, 45(12): W12411.

[8] KADDI Y, PROUST S, FAURE J B, et al. Unsteady flows in a compound open-channel: a laboratory experiment and a 1D+ model [C]//Proceedings of the 38th IAHR World Congress. Panama City: International Association for Hydro-Environment Engineering and Research, 2019: 2839-2848.

[9] LIU Jiaming, XIAO Yang, ZHOU Jian, et al. Unsteady flow in a compound channel during flooding: insights from a combined two-dimensional and three-dimensional numerical simulation[J]. Physics of Fluids, 2024, 36(8): 085124.

[10] 汪昊燃,王容,黄鹏年,等. 水文水力学结合的秦淮河流域洪水模拟与实时校正[J]. 河海大学学报(自然科学版),2023, 51(3): 25-30. (WANG Haoran, WANG Rong, HUANG Pengnian, et al. Research on flood simulation and real-time correction of Qinhuai River Basin combined with hydrology and hydraulics[J]. Journal of Hohai University (Natural Sciences), 2023, 51(3): 25-30. (in Chinese))

[11] 王雨洁,李致家,姚成,等. 基于分布式水文水动力耦合模型的秦淮河流域洪水模拟[J]. 河海大学学报(自然科学版),

2025,53(2):11-18. (WANG Yujie,LI Zhijia,YAO Cheng,et al. Flood simulation in the Qinhuai River Basin based on a coupled distributed hydrological and hydrodynamic model[J]. Journal of Hohai University (Natural Sciences),2025,53(2):11-18. (in Chinese))

[12] 汪晨辉,张汇明. 含滩地交汇河道水动力特性与掺混特征数值模拟[J]. 河海大学学报(自然科学版),2023,51(2):89-98. (WANG Chenhui,ZHANG Huiming. Hydrodynamic and mixing characteristics of river confluence with floodplain[J]. Journal of Hohai University (Natural Sciences),2023,51(2):89-98. (in Chinese))

[13] 李野,陈松灿. 基于物理信息的神经网络:最新进展与展望[J]. 计算机科学,2022,49(4):254-262. (LI Ye, CHEN Songcan. Physics-informed neural networks:recent advances and prospects[J]. Computer Science,2022,49(4):254-262. (in Chinese))

[14] RAISSI M,PERDIKARIS P,KARNIADAKIS G E. Physics informed deep learning (Part I):data-driven solutions of nonlinear partial differential equations[EB/OL]. (2017-11-28). <https://arxiv.org/abs/1711.10561>.

[15] RAISSI M,PERDIKARIS P,KARNIADAKIS G E. Physics informed deep learning (Part II):data-driven discovery of nonlinear partial differential equations[EB/OL]. (2017-11-28). <https://arxiv.org/abs/1711.10566>.

[16] QIAN K,MOHAMED A,CLAUDEL C. Physics informed data driven model for flood prediction;application of deep learning in prediction of urban flood development[EB/OL]. (2019-8-23). <https://arxiv.org/abs/1908.10312>.

[17] DONNELLY J,DANESHKHAH A,ABOLFATHI S. A physics-informed neural network surrogate model for tidal simulations [C]//5th ECCOMAS Thematic International Conference on Uncertainty Quantification in Computational Sciences and Engineering. Greece:Eccomas Proceedia,2023:836-844.

[18] FANOUS M,DANESHKHAH A,EDEN J M,et al. Hydro-morphodynamic modelling of mangroves imposed by tidal waves using finite element discontinuous Galerkin method[J]. Coastal Engineering,2023,182:104303.

[19] FENG Dongyu,TAN Zeli,HE Qizhi. Physics-informed neural networks of the Saint-Venant equations for downscaling a large-scale river model[J]. Water Resources Research,2023,59(2):e2022WR033168.

[20] 方卫华,徐孟启. 基于 PINNs 的圣维南方程组数据同化方法[J]. 水资源保护,2023,39(3):24-31. (FANG Weihua,XU Mengqi. Data assimilation method of Saint-Venant equations based on PINNs[J]. Water Resources Protection,2023,39(3):24-31. (in Chinese))

[21] 袁赛瑜,陈逸鸿,罗霄,等. 知识数据双驱动的感潮河网水动力智能模拟方法[J]. 水科学进展,2025,36(1):28-38. (YUAN Saiyu,CHEN Yihong,LUO Xiao,et al. Knowledge-and data-driven intelligent simulation method for tidal river network hydrodynamics[J]. Advances in Water Science,2025,36(1):28-38. (in Chinese))

[22] LAU Y L,KRISHNAPPAN B G. Discussion of “*velocity and discharge in compound channels*” by William R. C. Myers (June, 1987, Vol. 113, No. 6) [J]. Journal of Hydraulic Engineering,1989,115(5):688-689.

[23] STEPHENSON D,KOLOVOPOULOS P. Effects of momentum transfer in compound channels [J]. Journal of Hydraulic Engineering,1990,116(12):1512-1522.

[24] PROUST S,BOUSMAR D,RIVIÈRE N,et al. Energy losses in compound open channels[J]. Advances in Water Resources,2010,33(1):1-16.

[25] BOUSMAR D,ZECH Y. Momentum transfer for practical flow computation in compound channels[J]. Journal of Hydraulic Engineering,1999,125(7):696-706.

[26] GLOROT X , BENGIO Y . Understanding the difficulty of training deep feedforward neural networks[J]. Journal of Machine Learning Research, 2010, 9:249-256.

[27] RATHORE P,LEI Weimu,FRANGELLA Z,et al. Challenges in training PINNs:a loss landscape perspective[C] //Proceedings of the 41st International Conference on Machine Learning. Vienna: Open Review. net, 2024:1715.

[28] KESKAR N S,SOCHER R. Improving generalization performance by switching from Adam to SGD[EB/OL]. (2017-12-20). <https://arxiv.org/abs/1712.07628>.

[29] ZHU Jing’ ang, XUE Yiheng, LIU Zishun. A transfer learning enhanced physics-informed neural network for parameter identification in soft materials[J]. Applied Mathematics and Mechanics,2024,45(10):1685-1704.

[30] DESAI S,MATTHEAKIS M,JOY H,et al. One-shot transfer learning of physics-informed neural networks[EB/OL]. (2021-10-21). <https://arxiv.org/abs/2110.11286>.