

DOI: 10.14042/j.cnki.32.1309.2025.01.003

知识数据双驱动的感潮河网水动力 智能模拟方法

袁赛瑜^{1,2}, 陈逸鸿¹, 罗霄¹, 张汇明^{1,2}, 唐洪武^{1,2}

(1. 河海大学水灾害防御全国重点实验室, 江苏南京 210098; 2. 河海大学水利部水循环与水动力系统重点实验室, 江苏南京 210098)

摘要: 感潮河网地区大量水闸、泵站智慧高效的联合调度是实现河网活水提质的重要保障, 但以往的智能模拟方法缺乏物理可解释性, 难以准确描述感潮河网复杂的水动力过程。本文提出了一种知识数据双驱动的感潮河网水动力智能模拟方法, 应用于概化感潮河网和上海蕴南片感潮河网的水动力模拟。结果表明: 以人工神经网络为主干、以河网水流控制方程作为物理约束, 构建包含控制方程残差的人工神经网络损失函数, 不断迭代优化神经网络权重集直至损失函数满足要求, 从而实现同时具备物理可解释性和高效计算效率的感潮河网水动力智能模拟; 该方法区别于传统人工神经网络, 表现在所需的训练数据大幅度减少, 还可以得到没有训练数据断面的水动力过程; 该方法具有良好的模拟精度、计算效率以及鲁棒性。

关键词: 水动力模拟; 感潮河网; 智能模拟; 知识驱动; 数据驱动

中图分类号: TV13 **文献标志码:** A **文章编号:** 1001-6791(2025)01-0028-11

感潮河网地区地势平缓, 水动力弱, 且受到下游潮汐顶托, 水体常出现滞流和往复流现象, 自净能力差, 河网水质易恶化^[1]。通过大量水闸、泵站工程的联合调度提升水动力是提高河网水体自净能力和改善水质的重要手段, 而感潮河网水动力过程的精准快速模拟是重要前提。目前感潮河网的水动力模拟以水流运动方程计算和神经网络方法为主, 如上海河网^[2-3]。前者基于描述浅水水流运动的圣维南方程组, 通过对方程进行离散求解。这种方法通常需要将连续的水动力过程离散到有限数量的网格点, 为了保证计算精度, 需要划分比较精细的网格, 对于较大河网系统, 计算效率低。近年来, 神经网络等机器学习方法因其逼近非线性系统能力强、计算效率高等特点而越来越多地应用于水动力模拟和水文预报。这类方法使用数据驱动的人工神经网络代替圣维南方程组, 避开了方程求解过程, 通过大量水位、流量等数据进行训练学习, 实现快速地模拟和预测, 且通过更新神经网络算法可以进一步提升模型的计算速度^[4-6]。然而, 神经网络模型往往对训练数据的需求大、精准度要求高^[7-8], 而且缺乏物理可解释性。Raissi等^[9]在2019年提出了一种集成了数据约束和物理约束的计算方法, 可以弥补上述2种方法的不足。这种方法所需的训练数据量少, 缓解了数据稀缺对机器学习模型的限制, 而且因为加入物理约束而增加了可解释性, 已被成功应用于流体力学、弹性力学、传热系统和量子化学等领域^[10-13]。

本文提出一种知识数据双驱动的感潮河网水动力智能模拟方法, 并将其应用于上海蕴南片感潮河网, 实现感潮河网水动力的快速、精准模拟, 对感潮河网洪水快速预报、水动力时空格局优化提供有力支持。

收稿日期: 2024-07-15; 网络出版日期: 2024-11-01

网络出版地址: <https://link.cnki.net/urlid/32.1309.P.20241031.1744.002>

基金项目: 国家重点研发计划项目(2022YFC3202602); 国家自然科学基金项目(U2340221)

作者简介: 袁赛瑜(1987—), 男, 江苏南通人, 教授, 博士, 主要从事水力学及河流动力学方面的研究。

E-mail: yuansaiyu@hhu.edu.cn

1 模型原理与方法

1.1 模型框架

传统的人工神经网络模型将输入层的数据经过多个隐藏层计算后得到输出层的预测值, 这些预测值与实际值的差异为损失函数, 该函数指导优化算法调整网络权重, 从而完成人工神经网络的训练过程^[14]。但是, 对于没有提供训练数据的位置, 神经网络便无法依此过程完成训练, 而且训练结果是否满足客观物理规律不得而知。若将物理方程嵌入损失函数中, 计算每个输入样本对应输出值的方程残差, 以残差作为损失函数的一部分, 指导神经网络训练, 既可以指导无训练数据位置的神经网络训练, 训练得到的结果也满足给定的物理方程, 具有较好的可解释性。据此, 图1给出了知识数据双驱动(简称KDM)的感潮河网智能模拟方法框架, 主干部分为图1(a)部分所示的人工神经网络, 在计算损失函数时嵌入如图1(b)部分所示的物理方程, 对人工神经网络训练结果进行约束, 其中, ε 为人工神经网络的阈值, 当损失函数小于此阈值时表示训练完成, 本文取值为0.0001; J_f 为阻力项。

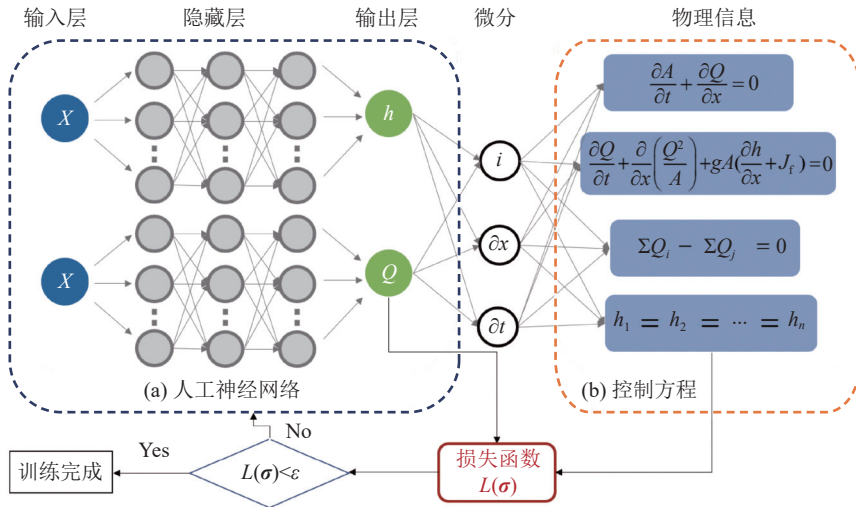


图1 知识数据双驱动的感潮河网智能模拟方法框架

Fig. 1 Framework of knowledge and data dual-driven tidal river network intelligent simulation method

该方法中, 人工神经网络作为主体框架, 负责处理和预测数据。神经网络主要由输入层、隐藏层和输出层构成。考虑到预测水位和流量预测中所需捕捉的特征可能不同, 这里分别采用2个相同尺寸的深度神经网络来实现对水位(h)和流量(Q)的预测, 神经网络的输入层 X 为

$$X = (x, n, t) \quad (1)$$

式中: x 为距河道第1个断面的距离; n 为河道编号; t 为时间。

以预测水位的深度神经网络为例, 第 i 层隐藏层的输出值(Z_{hi})可由式(1)计算:

$$Z_{hi} = f(W_{hi}Z_{h(i-1)} + B_{hi}) \quad (2)$$

式中: $f()$ 为用于提供非线性关系学习能力的激活函数; W_{hi} 和 B_{hi} 分别为第 i 层隐藏层的权重和偏置值; $Z_{h(i-1)}$ 为第 $i-1$ 层隐藏层的输出值。最后人工神经网络预测的水位(\hat{h})可由最后一层隐藏层 l 的权重(W_{hl})、偏置(B_{hl})和输出值(Z_{hl})依照式(2), 以相同方法计算。

1.2 知识数据双约束损失函数

数据约束部分的损失函数($L_1(\sigma)$)由神经网络预测值与给定初始条件、边界条件和水文测站观测值的均

方根差值构成:

$$L_1(\boldsymbol{\sigma}) = \omega_{ic}L_{ic} + \omega_{bc}L_{bc} + \omega_{ob}L_{ob} \quad (3)$$

式中: $\boldsymbol{\sigma}$ 为包含水位预测神经网络和流量预测神经网络全部权重和偏置的权重集; L_{ic} 、 L_{bc} 和 L_{ob} 分别为初始条件、边界条件和水文测站观测值对应的误差; ω_{ic} 、 ω_{bc} 和 ω_{ob} 分别为初始条件、边界条件和水文测站观测值对应误差的权系数。 L_{ic} 、 L_{bc} 和 L_{ob} 可分别由式(4)—式(6)计算。

$$L_{ic} = \frac{1}{N_{ic}} \sum_i^{N_{ic}} \left[\left(\widehat{h}(X, \boldsymbol{\sigma}_h) - h(X) \right)^2 + \left(\widehat{Q}(X, \boldsymbol{\sigma}_Q) - Q(X) \right)^2 \right], \quad X \in \Omega_{ic} \quad (4)$$

$$L_{bc} = \frac{1}{N_{bc}} \sum_i^{N_{bc}} \left[\left(\widehat{h}(X, \boldsymbol{\sigma}_h) - h(X) \right)^2 + \left(\widehat{Q}(X, \boldsymbol{\sigma}_Q) - Q(X) \right)^2 \right], \quad X \in \Omega_{bc} \quad (5)$$

$$L_{ob} = \frac{1}{N_{ob}} \sum_i^{N_{ob}} \left[\left(\widehat{h}(X, \boldsymbol{\sigma}_h) - h(X) \right)^2 + \left(\widehat{Q}(X, \boldsymbol{\sigma}_Q) - Q(X) \right)^2 \right], \quad X \in \Omega_{ob} \quad (6)$$

式中: N_{ic} 、 N_{bc} 和 N_{ob} 分别为初始条件、边界条件和水文测站观测值所用于计算的时空点数; $h(X)$ 和 $Q(X)$ 分别为水位和流量的参考解; $\widehat{h}(X, \boldsymbol{\sigma}_h)$ 和 $\widehat{Q}(X, \boldsymbol{\sigma}_Q)$ 分别为水位和流量的预测值, $\boldsymbol{\sigma}_h$ 和 $\boldsymbol{\sigma}_Q$ 分别为水位和流量预测神经网络的权重集; Ω_{ic} 、 Ω_{bc} 和 Ω_{ob} 分别为初始条件、边界条件和水文测站计算中的时空域。

考虑到真实感潮河网中绝大部分时空位置的实测数据难以获取, 无法依照此思路实现神经网络的训练过程, 且训练得到的结果是否满足河网物理规律也不得而知。因此, 引入一维圣维南方程组作为河道水流控制方程; 引入节点能量平衡方程作为河网分汇流节点控制方程, 计算各样本输出值对应的方程残差, 作为损失函数的一部分, 指导神经网络完成训练过程, 同时也为预测结果提供了物理依据。

一维圣维南方程组包括连续性方程和动量方程, 用于描述水位和流量的时空变化规律。一维圣维南方程^[15]为

$$\begin{cases} \frac{\partial A}{\partial t} + \frac{\partial Q}{\partial x} = 0 \\ \frac{\partial Q}{\partial t} + \frac{\partial}{\partial x} \left(\frac{Q^2}{A} \right) + gA \frac{\partial h}{\partial x} + gA \frac{n^2 Q |Q|}{A^2 R^{4/3}} = 0 \end{cases} \quad (7)$$

式中: A 为过水断面面积; t 为时间; x 为沿河道的距离; g 为重力加速度; n 为河道糙率; R 为河道的水力半径。

在河网模拟计算中, 除了需要对单条河道进行水力计算外, 还需要分汇流节点等内边界条件处的控制方程。在分汇流节点处, 圣维南方程组不再适用, 由以下质量守恒方程和节点水位方程控制^[15]:

$$\begin{cases} \sum Q_i - \sum Q_j = 0 \\ h_1 = h_2 = \dots = h_n \end{cases} \quad (8)$$

式中: $\sum Q_i$ 为河网节点上游各河段的入流流量之和; $\sum Q_j$ 为河网节点下游各河段的出流流量之和; h_i 为与河网节点处相连的第 i 条河段的水位, $i=1, 2, \dots, n$ 。水流质量守恒方程假设入流流量总和等于出流流量总和; 节点水位方程假设河网节点处不存在水位突变, 水位相等。

控制方程对应的知识约束损失函数 (L_{pde}) 可由以下公式计算:

$$L_{pde} = \frac{1}{N_{pde}} \sum_i^{N_{pde}} \left[\sum_j^4 r_j^2(X, \boldsymbol{\sigma}_h, \boldsymbol{\sigma}_Q) \right], \quad X \in \Omega_{pde} \quad (9)$$

式中: N_{pde} 为方程残差所用于计算的时空点数; r_j 分别为式(7)和式(8)中所示4个方程的残差; Ω_{pde} 为方程残差计算中的时空域。此时, 本方法的损失函数 ($L(\boldsymbol{\sigma})$) 由人工神经网络部分的损失函数 ($L_1(\boldsymbol{\sigma})$) 和方程对应损失函数 ($L_{pde}(\boldsymbol{\sigma})$) 组合而成:

$$L(\boldsymbol{\sigma}) = L_1(\boldsymbol{\sigma}) + L_{pde}(\boldsymbol{\sigma}) \quad (10)$$

1.3 权系数自适应调整

权系数 ω_{ic} 、 ω_{bc} 和 ω_{ob} 可以用来平衡不同损失项的数量级, 避免某些损失项因数量级较大而在训练过程中主导了其他损失项, 从而影响优化效果。而权系数的优选是随着不同求解问题和神经网络优化过程不断变化的, 人为调整权系数费时且难以获取权系数的最佳取值。本文中采用动态权系数法解决此问题, 该方法使权系数在神经网络权重更新过程中动态调整以平衡损失函数的梯度, 神经网络的权重更新过程可表示为

$$\sigma^k = \sigma^{k-1} - \eta (\omega_{ic}^{k-1} \nabla_{\sigma} L_{ic} + \omega_{bc}^{k-1} \nabla_{\sigma} L_{bc} + \omega_{ob}^{k-1} \nabla_{\sigma} L_{ob} + \nabla_{\sigma} L_{pde}) \quad (11)$$

式中: k 为神经网络的迭代步数; η 为用于决定神经网络参数更新幅度大小的学习率; ∇ 算子表示求梯度。第 k 次迭代权系数的估计值 $\widehat{\omega}_{ic}^k$ 、 $\widehat{\omega}_{bc}^k$ 和 $\widehat{\omega}_{ob}^k$ 可由下式计算:

$$\widehat{\omega}_{ic}^k = \frac{\max |\nabla L_{pde}|}{|\nabla L_{ic}|}, \quad \widehat{\omega}_{bc}^k = \frac{\max |\nabla L_{pde}|}{|\nabla L_{bc}|}, \quad \widehat{\omega}_{ob}^k = \frac{\max |\nabla L_{pde}|}{|\nabla L_{ob}|} \quad (12)$$

式(12)表示, 第 k 次迭代权系数的估计值以当前方程残差梯度的最大值与初始条件、边界条件、水文测站观测值对应误差梯度的平均值之比计算, 以保证各项损失函数在权重更新时的梯度在同一数量级。第 k 次迭代权系数的更新值为

$$\omega_{ic}^k = (1 - \theta) \omega_{ic}^{k-1} + \theta \widehat{\omega}_{ic}^k, \quad \omega_{bc}^k = (1 - \theta) \omega_{bc}^{k-1} + \theta \widehat{\omega}_{bc}^k, \quad \omega_{ob}^k = (1 - \theta) \omega_{ob}^{k-1} + \theta \widehat{\omega}_{ob}^k \quad (13)$$

式中: θ 为决定权系数更新快慢的系数, 本文中 θ 取值为 0.1, 以保证权重更新的稳定性。

由于输入数据之间的尺度差异较大, 在误差反向传播时可能会出现梯度爆炸的现象, 本文采用以下量纲一化方法将输入数据缩放到 $[-1, 1]$ 区间内:

$$X_{re} = 2 \frac{X - \min(X)}{\max(X) - \min(X)} - 1 \quad (14)$$

式中: X_{re} 为量纲一化的输入层。

1.4 参数设置

神经网络尺寸的选择对模拟结果有着至关重要的影响。若选择的神经网络尺寸过小, 将难以捕捉到输入和输出之间的复杂关系, 导致神经网络欠拟合; 若神经网络尺寸过大, 会过多地捕捉训练数据的细节, 导致过拟合问题, 同时增加计算的负担。在预试验中, 本文测试了增加隐藏层和增加神经元的案例, 结果显示增加的隐藏层和神经元会显著提升训练时间, 而对模拟精度几乎没有提升, 甚至过拟合导致精度降低。为此, 本文在模型验证中使用 2 个隐藏层, 每层 30 个神经元的全连接结构构造本方法中的神经网络部分, 加入系数为 0.01 的 L_2 正则化方法防止过拟合现象, 提高神经网络的鲁棒性。神经网络的激活函数 f 使用 \tanh 激活函数, 神经网络权重的初始化方法选择适用于对称激活函数 \tanh 的 xavier 初始化, 用于寻找最小损失 $\min |L(\sigma)|$ 的优化器使用 Adam, 神经网络的学习率为 0.005, 训练迭代次数为 30 000 次, 权系数 ω_{ic} 、 ω_{bc} 和 ω_{ob} 初始取值均为 10。

2 模型验证

2.1 案例设置

本文设置了概化河网案例, 用以探讨本方法模拟感潮河网水动力过程的可行性(图 2)。河网由 8 条河道和 4 个交汇分汊节点组成, 拥有 2 个入口和 2 个出口边界。入口边界给定非恒定流量过程, 出口边界给定潮位, 河道断面均为矩形, 河长为 1 000 m, 糙率为 $0.028 \text{ m}^{-1/3}/\text{s}$, 河道其他物理信息如表 1 所示。考虑到现实河流中存在水文测站可以提供当地的水位、流量等时间序列数据, 这里也提供若干断面(即水文测站)的时间序列水位和流量数据以提高模拟精度, 这些数据由一维水动力模拟软件 HEC-RAS 计算值提供。最后, 将本

方法预测结果与 HEC-RAS 软件计算结果对比, 分析本方法的可行性。




图2 求解案例示意

Fig. 2 Solution case diagram

表1 河道物理信息

Table 1 Physical information of the river channels

河道编号	河宽/m	底坡	初始流量/(m ³ /s)	河道编号	河宽/m	底坡	初始流量/(m ³ /s)
1-1	90	0.000 5	41.8	1-5	50	0.000 8	15.6
1-2	30	0.000 7	8.25	1-6	50	0.000 7	14.4
1-3	30	0.000 6	7.35	1-7	50	0.000 8	20.0
1-4	70	0.000 7	34.4	1-8	70	0.000 9	30.0

模拟案例参数设置如下: 使用 HEC-RAS 求解时, 入口边界为 1-8 和 1-7 河道上游, 分别设置为 50 ~ 130 m³/s 和 20 ~ 50 m³/s 的流量过程(图 3); 出口边界为 1-1 和 1-2 河道下游, 设置为潮位边界, 水位变动幅度为 20 cm(图 3); 计算时长为 24 h, 时间步长为 15 min, 河道每隔 100 m 设置 1 个断面, 共 88 个断面。使用 KDM 求解时, 训练的初始条件为 $t=0$ s 时全部河道各断面的水位和流量, 边界条件为 1-8 和 1-7 河道 $x=0$ m 以及 1-2 和 1-1 河道 $x=1\ 000$ m 处的水位、流量时间序列数据, 水文测站设在 8 条河道 $x=500$ m 处共 8 个, 计算中的 N_{ic} 、 N_{bc} 、 N_{ob} 和 N_{pde} 分别为 88、194、776 和 8 536。由于案例中提供的数据点比较稀疏, 为防止过拟合, 设置 L_2 正则化方法系数为 0.1。




图3 各案例入流边界的流量过程

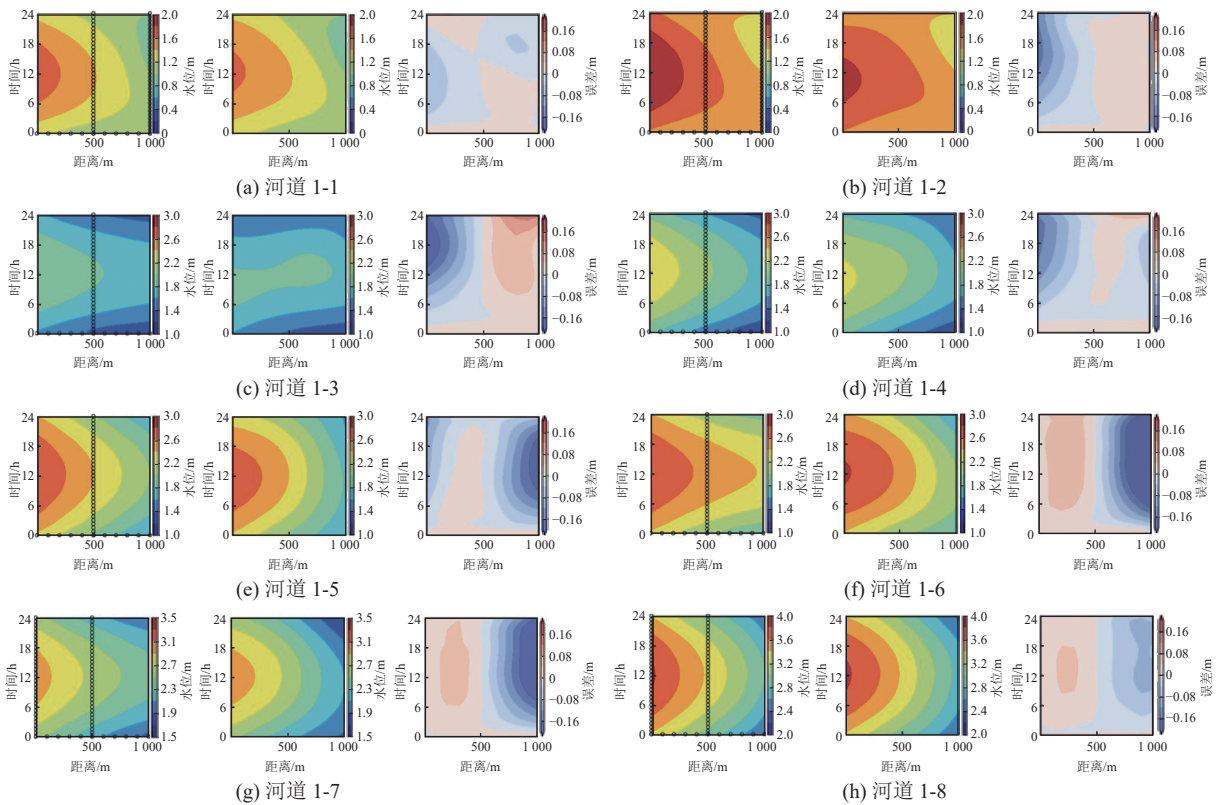
Fig. 3 Inflow boundary flow process of each cases

本文采用 L_2 相对误差衡量 KDM 模拟结果与 HEC-RAS 参考解之间的差异, 评估 KDM 的模拟效果。通过计算两者之间的欧氏距离, 并进行量纲一化处理, 以便比较不同规模的数据。对水位和流量的 L_2 相对误差 ε_h 、 ε_Q 可由下式计算:

$$\varepsilon_h = \frac{\|\widehat{h}(X, \sigma_h) - h(X)\|_2}{\|h(X)\|_2}, \quad \varepsilon_Q = \frac{\|\widehat{Q}(X, \sigma_Q) - Q(X)\|_2}{\|Q(X)\|_2} \quad (15)$$

2.2 案例模拟结果分析

图4为概化河网模拟中各河道水位KDM解和HEC-RAS参考解的结果对比图。显然, KDM方法显现出很高的精确性, 水位和流量的 L_2 相对误差分别为3.83%和7.49%, 潮汐边界对水位的影响主要集中在河道1-7和1-8下游500 m范围内, 这种影响能被KDM很好地捕捉到。其中, 水位的最大误差在0.2 m左右, 这些位置集中在分汇流节点附近, 误差成因主要是交汇口的壅水和水位突变。分汇流节点处时常伴随着复杂的水流结构^[16-19], 节点水位方程和质量守恒无法精确捕捉分汇流节点处的水动力过程。若以更加精确的方程实现对河网分汇流节点的控制, 本方法的预测精度将进一步提升。同时, 节点附近缺乏测量数据也是导致误差的原因之一, 可以通过增设交汇/分汉口附近的测站以提高水动力的预测精度。在模拟过程中, 权系数 ω_{ic} 、 ω_{bc} 和 ω_{ob} 由初始值10上升至10 000附近, 最后稳定在9 000左右。这表明, 训练初期 $L_1(\sigma)$ 的极速收敛导致中期下降速度远小于 $L_{pde}(\sigma)$, 并且一直保持这样的趋势直至训练完成。除了计算精度, 本方法的计算效率很高, 本案例中HEC-RAS的计算时间为47 s, 而训练完成之后的KDM为1 s。



注: 各分图左、中、右图分别为参考解、KDM解、差值。

图4 案例中各河道水位参考解和KDM解对比

Fig. 4 Comparison between reference and KDM solution for the water level of each channels in this case

2.3 鲁棒性分析

感潮河网实际测量数据往往会伴随有一定的噪声。为检验本方法的抗噪声能力, 在参考解中加入不同水平的噪声(0.5%、1%、2%、5%、10%)用于KDM训练, 对应误差如表2所示。随着噪声水平从0.5%增加到2%, KDM解仍然具有优异的表现, 水位误差控制在6%以内, 流量误差略微升高到19%左右; 当噪声水平从5%增加到10%时, 水位误差从6%左右增加到10%左右, 流量误差升高到26%左右, 模拟结果受影响较

大。KDM 在 5% 内的噪声影响下仍可以精确模拟感潮河网水动力过程，表明本方法具有良好的鲁棒性。

表 2 噪声水平及其对应的 L_2 误差
Table 2 Noise level and its corresponding L_2 error

单位: %

噪声水平	水位误差	流量误差	噪声水平	水位误差	流量误差
0	3.83	7.49	2	5.83	19.65
0.5	3.66	5.08	5	9.78	17.86
1	3.92	15.91	10	9.60	25.63

3 模型应用

3.1 模拟案例介绍

本节通过模拟真实感潮河网来进一步验证方法的可行性。上海蕴南片河网由杨树浦港水系(包括虬江、东走马塘和杨树浦港)、虹口港水系(包括南泗塘、西泗塘、沙泾港、俞泾浦、虹口港)、彭越浦-木渎港水系(包括东茭泾、彭越浦、桃浦河、木渎港)和新江湾城水系组成, 全片总面积为 173.3 km², 片内河道总长 159.51 km, 河道总面积为 3.69 km², 河网密度为 0.92 km/km²。该区域水系较复杂, 河网水动力不足、水流往复现象突出^[6], 通过河网水闸调度提升河网水动力是改善水环境状况的主要措施。本案例模拟了蕴藻浜以南和苏州河以北的整个河网共 33 条河道 28 个节点的水动力过程, 模拟情景为 2022 年 5 月 1 日全天, 选择往复流现象突出的虹口港水系进行水动力模拟结果分析。虹口港水系存在 7 条河道(河道编号为 2-1—2-7)、3 个分汇流节点以及 3 个水文测站, 如图 5 所示。

考虑到感潮河网的复杂性, 本案例神经网络设置 3 层隐藏层, 每层 30 个神经元。模拟过程中, 不提供初始条件, 给定河网南侧 4 个闸泵(虹口港水闸、彭越浦泵闸、真如港泵闸、木渎港泵闸)以及北侧 5 个闸泵(郝桥港泵闸、西泗塘泵闸、东茭泾泵闸、西弥浦水闸、桃浦河泵闸)的闸内当日水位、流量数据作为边界

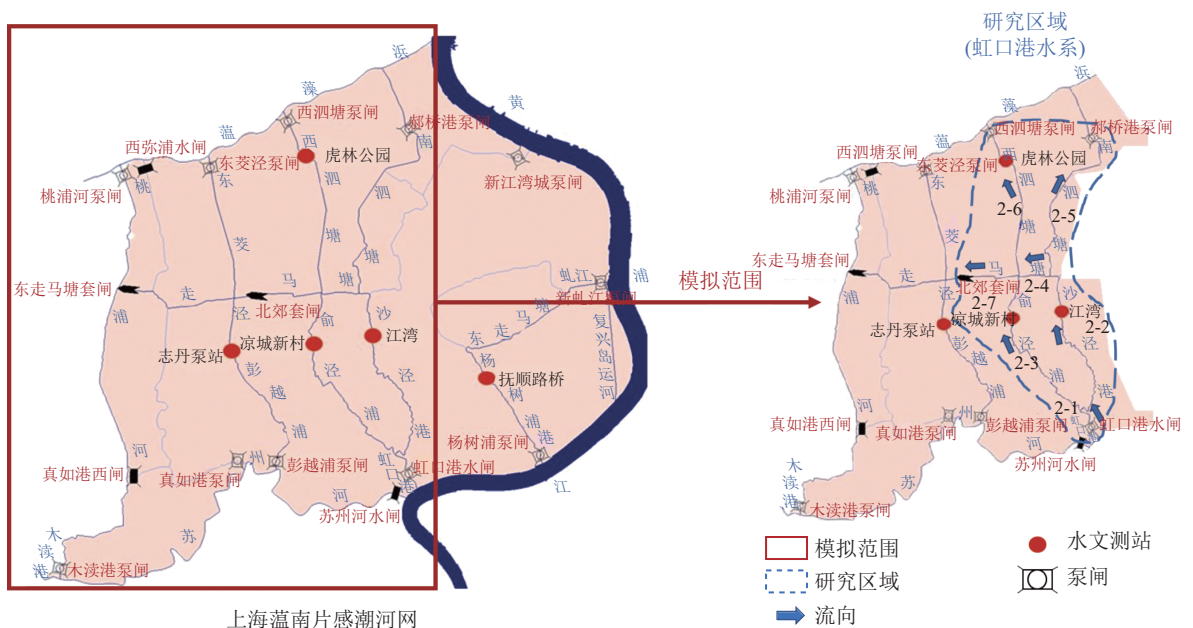



图 5 上海河网模拟范围及研究区域示意

Fig. 5 Diagram of Shanghai river network simulation and research area


条件。这里为了计算简便, 未考虑闸门调度, 直接给定闸内数据, 数据的时间间隔为 5 min。河网内存在江湾、凉城新村和虎林公园 3 个水文测站。以下分别讨论虎林公园作为训练、江湾及凉城新村作为验证, 虎林公园及江湾作为训练、凉城新村作为验证, 以及 3 个测站同时作为训练的 3 种工况下 3 个水文测站真实测量数据与模拟结果的吻合程度, 并将 3 个水文测站均用于训练, 分析上海蕴南片河网虹口港水系的水动力模拟结果。模拟过程中, 时间步长为 15 min, 整个模拟河网选取 187 个断面参与残差计算。

3.2 模拟结果验证


以虎林公园水文测站作为训练数据, 其余两测站作为验证, 模拟水位、流量结果如图 6(a)、图 6(b)所示。由于缺乏初始水动力数据, 且俞泾浦、沙泾港处均不存在训练数据, 两河的分流比以及水面坡降都难以确定, 位于两河上的凉城新村和江湾水文测站的水位模拟结果在关闸时刻基本与实测值吻合, 但是在开闸时刻的涨落趋势和幅度难以预测。以虎林公园、江湾水文测站作为训练数据, 凉城新村作为验证的模拟结果如图 6(c)、图 6(d)所示。可以看到, 在给定了江湾的水位、流量数据之后, 凉城新村的水位时间序列数据已经基本与实测数据吻合; 流量模拟结果也得到了很大的改善, 但仍存在部分误差。将 3 个测站的数据均作为训练数据的模拟结果如图 6(e)、图 6(f)所示。从 3 个测站的实测水位流量可以看出, 主要的开闸时间




(a) 虎林公园测站作为训练数据的水位模拟结果




(b) 虎林公园测站作为训练数据的流量模拟结果




(c) 虎林公园和江湾测站作为训练数据的水位模拟结果



(d) 虎林公园和江湾测站作为训练数据的流量模拟结果



(e) 3 个测站均作为训练数据的水位模拟结果



(f) 3 个测站均作为训练数据的流量模拟结果

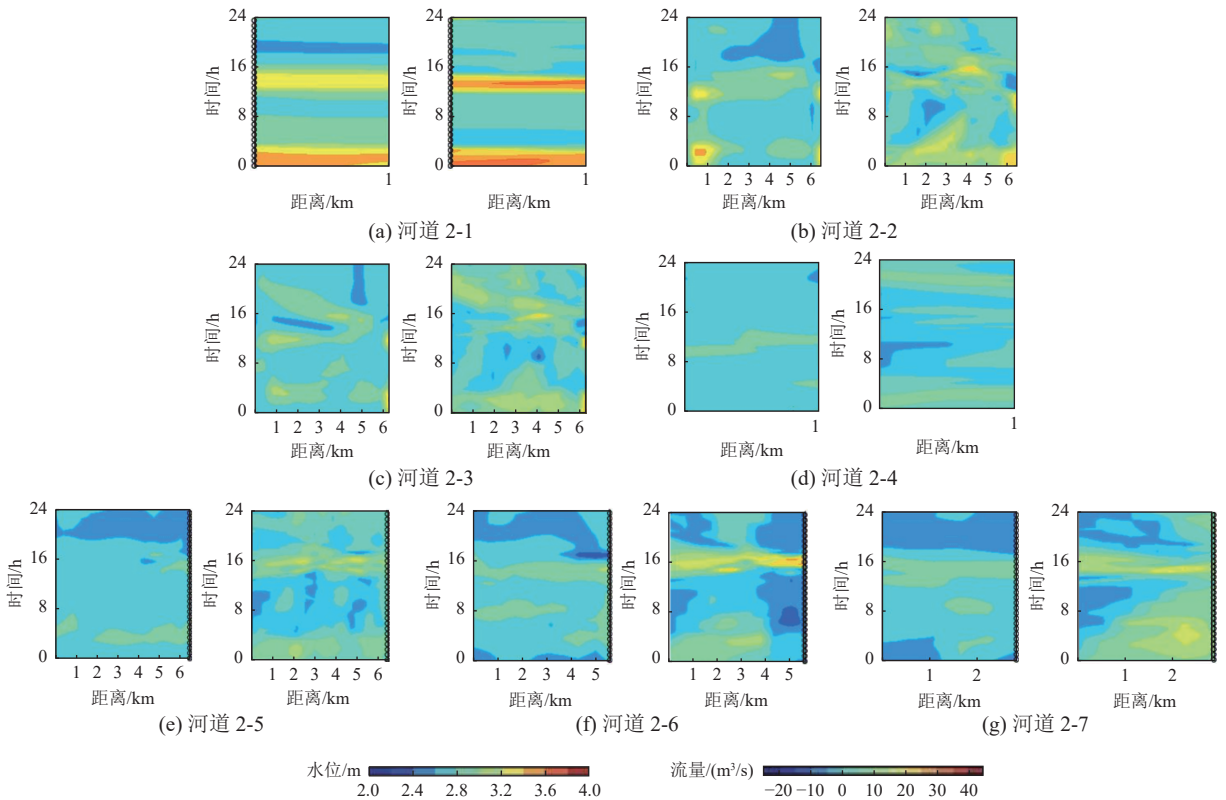
图 6 不同数量水文测站提供训练数据下的模拟结果

Fig. 6 Simulation results with training data from different numbers of hydrological stations

在0~4 h和12~18 h,在这2个时间段中,3个测站的水位受到潮汐影响而产生波动,流量也随之发生剧烈震荡,在这种影响下,3个测站的水位、流量时间序列数据也都得到了很好的模拟,且变化趋势也更加平滑,部分波动数据被模型认为是测量误差而没有进行学习,这表示潮汐变化过程能够被捕捉到,也再次表明本方法具有良好的鲁棒性。

3.3 虹口港水动力模拟结果分析

虹口港水系各河道的水位、流量模拟结果如图7所示。当日0~4 h及12~16 h左右为虹口港开闸时间,虹口港闸内水位提升了0.5 m左右,流量提升了 $30 \text{ m}^3/\text{s}$ 左右,河道2-1的水动力也因此得到了明显的提升;河道2-2与2-3位于河道2-1下游,且拥有相似的分流比,两河道水动力相当,都能很好地排出河道积水;河道2-5和河道2-6分别与河道2-2和河道2-3下游相连,且4条河道流向基本一致,具有大致相同的水动力特征;河道2-4和河道2-7作为东西走向的河道,几乎与其余河道正交,且南北侧闸门启闭时间接近,因此,水动力较强的南北走向河道中的水流难以流入这2条河道,导致其水动力较差,整体流量较小,水流往复现象严重。这种往复水流往往不利于水体自净和活水提质,是河网局部水质变差的重要原因^[3]。



注:各分图左、右图分别为水位和流量模拟结果。

图7 各河道水位流量模拟结果示意

Fig. 7 Diagram of water level and flow rate simulation results for each channels

4 结 论

本文提出了知识数据双驱动有感潮河网水动力智能模拟方法,应用于感潮河网案例的水动力模拟,并与河网水动力模拟软件的计算结果进行验证分析,同时应用于上海蕴南片感潮河网水动力模拟。主要结论

如下:

(1)本方法以河网水流控制方程约束人工神经网络,在保证计算效率的基础上,提高了物理可解释性,而且需要的训练数据大幅度减少,还可以得到没有训练数据断面的水位和流量。

(2)在感潮河网案例模拟中,该方法能够捕捉潮汐对水位的影响,且具有较高的模拟精度和良好的鲁棒性。由于分汇节点处水流复杂、水位变化大,水动力模拟较现实河网存在一定偏差。为此,在控制方程的选取方面仍然有待优化,可以将节点水位方程和质量守恒方程替换为更加准确的节点控制方程,实现对分汇流节点处水动力过程的精准捕捉以增加模拟精度。此外,针对水位梯度在分汇节点处的突变特性,可以通过在这些关键位置增设水文测站来有效降低预测偏差。上海蕴南片感潮河网水动力模拟结果显示,虹口港水系中东西走向的河道水动力较弱,难以排出往复积水,导致河网水质变差。可以通过控制南北闸门启闭及分汇流节点处的工程措施控制分流比,提升东西走向河道的水动力。

(3)本方法未来可以将水闸、泵站的调度规则纳入模型中,进一步耦合河网水环境、水生态相关控制方程,构建感潮河网水动力-水质-水生态耦合智能模型,服务于感潮河网地区水问题综合治理,为流域数字孪生、国家水网建设提供支撑。

参考文献:

- [1] TANG H W, YUAN S Y, CAO H. Theory and practice of hydrodynamic reconstruction in plain river networks[J]. *Engineering*, 2023, 24: 202-211.
- [2] 唐洪武, 雷燕, 顾正华. 河网水流智能模拟技术及应用[J]. *水科学进展*, 2008, 19(2): 232-237. (TANG H W, LEI Y, GU Z H. Intelligence simulation technique for river net flow and its application[J]. *Advances in Water Science*, 2008, 19(2): 232-237. (in Chinese))
- [3] 闫毓, 袁赛瑜, 唐洪武, 等. 上海蕴南水利控制片河网水动力再造[J]. *河海大学学报(自然科学版)*, 2021, 49(4): 329-334, 365. (YAN Y, YUAN S Y, TANG H W, et al. Hydrodynamic reconstruction of Wennen river network in Shanghai City[J]. *Journal of Hohai University (Natural Sciences)*, 2021, 49(4): 329-334, 365. (in Chinese))
- [4] 邓超, 陈春宇, 尹鑫, 等. 融合数据同化与机器学习的流域径流模拟方法[J]. *水科学进展*, 2023, 34(6): 839-849. (DENG C, CHEN C Y, YIN X, et al. Catchment runoff simulation by coupling data assimilation and machine learning methods[J]. *Advances in Water Science*, 2023, 34(6): 839-849. (in Chinese))
- [5] 师鹏飞, 赵西键, 徐辉荣, 等. 融合相空间重构和深度学习的径流模拟预测[J]. *水科学进展*, 2023, 34(3): 388-397. (SHI P F, ZHAO Y J, XU H R, et al. Simulation and prediction of streamflow based on phase space reconstruction and deep learning algorithm[J]. *Advances in Water Science*, 2023, 34(3): 388-397. (in Chinese))
- [6] 张力, 王红瑞, 郭珪楠, 等. 基于时序分解与机器学习的非平稳径流序列集成模型与应用[J]. *水科学进展*, 2023, 34(1): 42-52. (ZHANG L, WANG H R, GUO B N, et al. Integrated model and application of non-stationary runoff based on time series decomposition and machine learning[J]. *Advances in Water Science*, 2023, 34(1): 42-52. (in Chinese))
- [7] FENG D Y, TAN Z L, HE Q Z. Physics-informed neural networks of the saint-venant equations for downscaling a large-scale river model[J]. *Water Resources Research*, 2023, 59(2): e2022wr033168.
- [8] WANG N Z, ZHANG D X, CHANG H B, et al. Deep learning of subsurface flow via theory-guided neural network[J]. *Journal of Hydrology*, 2020, 584: 124700.
- [9] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [10] JIN X W, CAI S Z, LI H, et al. NSFnets (navier-stokes flow nets): physics-informed neural networks for the incompressible navier-stokes equations[J]. *Journal of Computational Physics*, 2021, 426: 109951.
- [11] TAO F, LIU X, DU H D, et al. Physics-informed artificial neural network approach for axial compression buckling analysis of thin-walled cylinder[J]. *AIAA Journal*, 2020, 58(6): 2737-2747.
- [12] WANG Y L, SHI L S, HU X L, et al. Multiphysics-informed neural networks for coupled soil hydrothermal modeling[J]. *Water Resources*

[Research](#), 2023, 59(1): e2022WR031960.

- [13] FANG Z W, ZHAN J. Deep physical informed neural networks for metamaterial design[J]. *IEEE Access*, 2019, 8: 24506-24513.
- [14] SIETSMA J, DOW R J F. Creating artificial neural networks that generalize[J]. *Neural Networks*, 1991, 4(1): 67-79.
- [15] 吴家阳, 徐学军, 程永光. 一种改进的一维河网水动力解法及其应用[J/OL]. *工程科学与技术*, 2024(2024-04-11)[2024-09-09]. <https://jsuese.scu.edu.cn/zh/article/doi/10.12454/j.jsuese.202300374/>. (WU J Y, XU X J, CHENG Y G. An improved hydrodynamic solution for one-dimensional river networks and its applications[J/OL]. *Engineering Science and Technology*, 2024(2024-04-11) [2024-09-09]. <https://jsuese.scu.edu.cn/zh/article/doi/10.12454/j.jsuese.202300374/>. (in Chinese))
- [16] YUAN S Y, TANG H W, LI K, et al. Hydrodynamics, sediment transport and morphological features at the confluence between the Yangtze River and the Poyang Lake[J]. *Water Resources Research*, 2021, 57(3): e2020WR028284.
- [17] JIANG C Y, CONSTANTINESCU G, YUAN S Y, et al. Flow hydrodynamics, density contrast effects and mixing at the confluence between the Yangtze River and the Poyang Lake channel[J]. *Environmental Fluid Mechanics*, 2023, 23(2): 229-257.
- [18] YUAN S Y, TANG H W, XIAO Y, et al. Water flow and sediment transport at open-channel confluences: an experimental study[J]. *Journal of Hydraulic Research*, 2018, 56(3): 333-350.
- [19] YUAN S Y, ZHU Y Q, TANG H W, et al. Planform evolution and hydrodynamics near the multi-channel confluence between the Yarlung Zangbo River and the delta of the Niyang River[J]. *Geomorphology*, 2022, 402: 108157.

Knowledge- and data-driven intelligent simulation method for tidal river network hydrodynamics*

YUAN Saiyu^{1,2}, CHEN Yihong¹, LUO Xiao¹, ZHANG Huiming^{1,2}, TANG Hongwu^{1,2}

(1. *The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China*; 2. *Key Laboratory of Hydrologic-Cycle and Hydrodynamic-System of Ministry of Water Resources, Hohai University, Nanjing 210098, China*)

Abstract: The intelligent and efficient joint scheduling of numerous sluices and pumping stations in tidal river networks is an important guarantee for improving water quality through increasing water mobility in these systems. However, previous intelligent simulation methods lack physical interpretability, making it difficult to accurately describe the complex hydrodynamic process in tidal river networks. This paper proposes a knowledge- and data-driven intelligent simulation method for tidal river network, which is applied to the hydrodynamic simulation of a generalized tidal river network and the Wrennan part of the Shanghai tidal river network. This method takes artificial neural network (ANN) as the backbone and incorporates the river network flow control equations as physical constraints, and an ANN loss function is constructed by including the residuals of the control equations. The ANN weight set is iteratively optimized until the loss function meets the required criteria, thereby achieving a hydrodynamic intelligent simulation of tidal river network with both physical interpretability and high computational efficiency. This method differs from traditional ANN approaches in that it greatly reduces the amount of training data required and can also predict the hydrodynamic processes in sections without training data. This method has good simulation accuracy, computational efficiency, and robustness.

Key words: hydrodynamic simulation; tidal river network; intelligent simulation; knowledge driven; data driven

* The study is financially supported by the National Key R&D Program of China (No. 2022YFC3202602) and the National Natural Science Foundation of China (No. U2340221).