

黄浩翔, 黄伟鹏, 黄瑾, 等. 基于时序图神经网络和强化学习的排水系统智能调度[J]. 净水技术, 2026, 45(9): 173-181.

Huang H X, Huang W P, Huang J, et al. Intelligent control of drainage systems based on temporal graph neural networks and reinforcement learning[J]. Water Purification Technology, 2026, 45(9): 173-181.

基于时序图神经网络和强化学习的排水系统智能调度

黄浩翔¹, 黄伟鹏¹, 黄瑾², 丰强强², 冯路建³, 信昆仑^{1,*}

(1. 同济大学环境科学与工程学院, 上海 200092; 2. 上海市城市建设设计研究总院<集团>有限公司, 上海 200125; 3. 宁波水表<集团>股份有限公司, 浙江宁波 315032)

摘要 【目的】为了应对城市内涝与合流制溢流频发导致的排水系统运行挑战,以及传统水力模型计算能力的瓶颈,本文提出了1种基于时序图神经网络(TGNN)和强化学习(RL)的排水系统智能调度方法。【方法】本文阐述了1种耦合TGNN与RL的算法,搭建了“状态预测-决策优化”的智能调度模型,使用TGNN预测管网运行状态,采用RL实现最小化内涝积水与溢流体积,兼顾预测精度与调度效率,并将其应用于H市某排水系统。【结果】TGNN具有较高的预测精度,单步预测纳什系数可达0.9999;TGNN计算速度相较于暴雨洪水管理模型提高约25倍;在各测试降雨情景下,内涝积水与溢流的总体积为现状规则控制的40%~67%;在监测数据稀疏时,仍能够准确预测管网运行状态且调度效果相近。【结论】本文提出的基于TGNN和RL的排水系统智能调度方法,能够对排水系统运行状态进行精准快速的预测,并削减内涝和溢流体积,提高了排水系统的运行效率并且具备较好的鲁棒性,为推动排水系统提质增效提供参考。

关键词 时序图神经网络; 强化学习; 排水系统; 状态预测; 实时控制方法

中图分类号: TU992 文献标志码: A 文章编号: 1009-0177(2026)09-0173-09

DOI: 10.15890/j.cnki.jsjs.2026.09.019

Intelligent Control of Drainage Systems Based on Temporal Graph Neural Networks and Reinforcement Learning

Huang Haoxiang¹, Huang Weipeng¹, Huang Jin², Feng Qiangqiang², Feng Lujian³, Xin Kunlun^{1,*}

(1. College of Environmental Science and Engineering, Tongji University, Shanghai 200092, China;

2. Shanghai Urban Construction Design and Research Institute <Group> Co., Ltd., Shanghai 200125, China;

3. Ningbo Water Meter <Group> Co., Ltd., Ningbo 315032, China)

Abstract [Objective] To address the operational challenges of drainage systems caused by frequent urban waterlogging and combined sewer overflows, as well as the computational bottlenecks of traditional hydraulic models, an intelligent control methodology anchored in temporal graph neural networks (TGNN) and reinforcement learning (RL) is developed. [Methods] An intelligent control model featuring a "state prediction-decision optimization" architecture was developed by coupling TGNN with RL. TGNN was employed to forecast the operational states of the pipe network, while RL was employed to minimize the total volume of waterlogging and overflow, thereby balancing prediction accuracy with control efficiency. The proposed method was subsequently applied to a drainage system in City H. [Results] TGNN exhibited high predictive precision, with the Nash-Sutcliffe efficiency for single-step prediction reaching 0.9999. Notably, the computational speed of TGNN was approximately 25 times that of the storm water management model. Under various test rainfall scenarios, the aggregate volume of waterlogging and overflow was contained at 40%–67% of the levels

[收稿日期] 2026-01-07

[基金项目] 国家自然科学基金(52470109)

[作者简介] 黄浩翔(2002—),男,硕士研究生,研究方向为给排水智慧管网理论与技术,E-mail: 2431330@tongji.edu.cn。

[通信作者] 信昆仑(1977—),教授,研究方向为水资源与给水排水系统设计与运行最优化,E-mail: xkl@tongji.edu.cn。

observed under existing rule-based controls. Furthermore, accurate state prediction and effective control were maintained even when the model was confronted with sparse monitoring data. [Conclusion] This paper proposes that the TGNN and RL approach enables precise, rapid forecasting and significantly mitigates the total volume of waterlogging and overflow. It enhances operational efficiency and exhibits substantial robustness, thereby furnishing a vital reference for catalyzing the qualitative upgrading and efficiency optimization of drainage systems.

Keywords temporal graph neural network (TGNN); reinforcement learning (RL); drainage system; state prediction; real-time control method

排水系统作为城市重要基础设施,负责收集、运输和排放市政污水、工业废水以及部分雨水,发挥了巨大作用。快速城市化带来的排污负荷激增与气候变化诱发的极端降雨,共同加剧了城市内涝及合流制溢流(CSO)风险。如何在保障排水系统安全稳定运行的基础上提升其运行效率,实现智慧化控制和智慧化调度,是当前排水系统调度研究的关键之一^[1]。

目前,我国许多城市排水管网中闸站、泵站等设施仍十分依赖人工经验调度,其决策调度并非最优,已经无法满足日益复杂的要求^[2]。为突破传统调度的效率与精度瓶颈,智能调度技术应运而生。该技术融合系统状态预测与人工智能决策算法,通过对泵站、调蓄池及闸阀等关键设施的协同实时控制,实现排水系统的全局优化运行。

排水系统实时控制是指根据实时监测数据动态调整排水设施的运行策略,相对于基于规则的控制(RBC),多基于模型预测控制实现^[3]。许多研究表明,模型预测控制在减少溢流污染^[4]、污水处理厂入流控制^[5]、污染物控制^[6]上实现了良好效果。近年来,随着人工智能技术的发展,基于强化学习(RL)的调度方法逐渐成为排水系统调度领域的研究热点。该方法通过智能体与环境的交互学习机制,显著突破了决策效率瓶颈。然而,无论是模型预测控制的在线迭代求解还是强化学习的智能体训练,均高度依赖于仿真环境进行状态推演。尽管传统机理模型具备较高的预测精度,但其计算负荷大、对监测数据依赖性强以及参数率定维护烦琐等问题^[7-8],严重制约了其在排水系统实时控制领域的应用。

为克服机理模型计算瓶颈,基于人工神经网络的数据驱动方法被广泛用于构建排水系统状态预测模型^[9-10]。传统神经网络难以捕捉管网复杂的拓扑结构,而图神经网络虽能提取空间特征^[11],却常忽

略系统的动态时变特性。鉴于此,融合了时序建模能力的时序图神经网络(TGNN)应运而生。该方法能够同时捕捉管网的空间依赖关系与时间演化规律,但目前其在排水系统预测领域的应用尚处起步阶段,具有进一步深化研究的潜力。

本文提出了1种基于TGNN和RL的排水系统智能调度方法,搭建了耦合TGNN与RL的智能调度模型并将其应用于H市某排水系统,能够精准预测排水系统运行状态,减少内涝和CSO,提高排水系统运行效率。

1 研究区域

研究案例位于我国东部H市中心城区,研究区域面积为27.65 km²,主要为住宅区。该区域排水系统为合流制管网。暴雨洪水管理模型(SWMM)包含115个检查井、115根管段、2座泵站(CC泵站、JK泵站)。其中CC泵站配有2台污水截流泵(CC-S1、CC-S2)与2台雨水泵(CC-R1、CC-R2),JK泵站配有1台污水截流泵(JK-S)与2台雨水泵(JK-R1、JK-R2)。系统设置5个末端出水口,其中1个通过截流干管连接至污水处理厂,其余4个为CSO排放口。污水截流泵负责将截流倍数内的合流污水输送至污水处理厂,雨水泵负责在降雨量超过系统截流能力时,将雨水通过CSO排放口排入收纳水体,以保障管网防涝安全。该管网系统的SWMM模型如图1所示。各泵基于规则控制,各泵类型与启闭液位如表1所示。

2 研究方法

2.1 TGNN

使用的TGNN基于边缘聚合图注意力模块(EGAT)与门控循环单元(GRU)搭建。该TGNN采用双层时空模块级联结构,由2层时空模块以及2个预测头组成。输入的节点和边的原始特征 X_n 和 X_e ,经过第一层时空模块得到初步时空嵌入 $\{h_i^{(1)}, e_{ij}^{(1)}\}$,然后第二层时空模块接收第一层输出作为输




图 1 研究区域 SWMM 模型

Fig. 1 SWMM Model in Study Area

入,生成高层时空表征 $\{h_i^{(2)}, e_{ij}^{(2)}\}$, 捕捉长程时空依赖,最后通过独立的预测头生成节点与边的预测结果,如式(1)。

$$\hat{y}_v = W_v h_i^{(2)} + b_v, \hat{y}_e = W_e e_{ij}^{(2)} + b_e \quad (1)$$

其中: W_v, W_e ——可学习权重矩阵;

b_v, b_e ——可学习偏置向量;

$h_i^{(2)}, e_{ij}^{(2)}$ ——节点 i 、边 (i, j) 在第二层的隐藏特征;

$\hat{y}_v, \hat{y}_e$ ——节点和边的预测结果。

每层的时空模块包含空间聚合模块与时序更新模块。空间聚合模块基于 EGAT 实现节点与边的特征增强,通过多头注意力机制动态聚合邻居信息,显式建模边特征对节点表示的影响,其计算如式(2)。

$$h_i^{(l)} = \text{EGAT}(h_i^{(l-1)}, e_{ij}^{(l-1)}, \mathcal{N}_i) \quad (2)$$

其中: $h_i^{(l)}, h_i^{(l-1)}$ ——第 l 层、第 $l-1$ 层节点嵌入;

$e_{ij}^{(l-1)}$ ——第 $l-1$ 层边特征;

$\mathcal{N}_i$ ——邻居集合。

表 1 研究区域的泵类型与启闭液位

Tab. 1 Pump Types and Operation Water Levels in Study Area

泵名	污水泵			雨水泵			
	CC-S1	CC-S2	JK-S	CC-R1	CC-R2	JK-R1	JK-R2
开启液位/m	0.8	1.0	4.0	1.2	1.4	4.2	4.3
关闭液位/m	0.5	0.5	1.0	0.5	0.5	1.2	1.2

时序更新模块使用双 GRU 分支分别处理节点与边的时序演化,节点 GRU 和边 GRU 基于历史状态 $s_i^{(t-1)}$ 和当前 EGAT 输出 $h_i^{(l,t)}$, 更新节点时序状态,如式(3)。

$$s_i^{(t)} = \text{GRU}(s_i^{(t-1)}, h_i^{(l,t)}) \quad (3)$$

其中: $s_i^{(t-1)}$ ——节点和边的历史状态;

$h_i^{(l,t)}$ ——当前时刻 EGAT 的输出。

将排水管网抽象为有向图,如式(4)。

$$\mathcal{G} = (\mathcal{V}, \mathcal{E}) \quad (4)$$

其中: $\mathcal{G}$ ——排水管网抽象得到的有向图;

$\mathcal{V}$ ——节点集合;

$\mathcal{E}$ ——边集合, $\mathcal{E} \subseteq \mathcal{V} \times \mathcal{V}$, 表示节点间连接关系。

排水管网中的各种设施简化成图论中的节点和边,比如检查井、调蓄池、排放口等设施可以简化成节点,其输入特征 X_n 包含各节点(检查井、调蓄池与排放口)的入流量、水深、水头;管段、泵等设施可

以简化成边,其输入特征 X_e 包含各管段的直径、长度、流量、水深以及泵的流量。基于 EGAT 的空间聚合模块能够通过聚合其邻居节点的特征以及对应的边特征进行每个节点的特征更新。基于双 GRU 分支的时序更新模块动态更新时序状态,捕捉长期依赖,帮助记忆历史降雨的长程影响。最后基于图神经网络聚合邻居的拓扑信息得到各节点和边的嵌入,基于此进行预测,并根据预定义的损失函数通过反向传播优化式(1)中的可学习权重矩阵 W 。

2.2 RL

RL 研究的是智能体如何通过与环境交互学习最优策略,以最大化累积奖励,其核心思想是让智能体在试错中学习,通过奖励信号引导智能体逐步改进决策。在排水系统智能调度问题中,环境为排水管网运行状态预测模型,其能根据智能体做出的动作与入流等边界条件实时计算得到状态与奖励。动作是指控制设施的运行控制量,如泵的启闭等。状态是指节点、管段、泵等设施的物理量,如管段流量、

节点水头等。奖励则是与控制目标相关的量,如内涝积水减少量等。

本文基于近端策略优化算法(PPO)搭建排水系统强化学习智能调度模型。传统策略梯度方法每次更新策略后需重新采样新数据,导致样本利用率低、训练不稳定等问题。PPO通过重要性采样复用旧数据,其允许用旧策略的数据估计新策略的期望。在每一代中,先通过用旧策略与环境交互,收集轨迹数据,然后对每个时间步计算新旧策略的概率比,最后用概率比调整旧数据的权重,优化新策略的目标。

PPO通过裁剪概率比限制策略更新幅度避免因更新步长过大导致的性能崩溃。其目标函数结合了重要性采样和裁剪机制,如式(5)。

$$L^{\text{CLIP}}(\theta) = \mathbb{E}_t[\min(r_t(\theta)\hat{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)\hat{A}_t)] \quad (5)$$

其中: $L^{\text{CLIP}}(\theta)$ ——PPO 裁切目标函数;

$\mathbb{E}_t[\cdot]$ ——对旧策略采集的轨迹样本在各时间步 t 上求期望;

$r_t(\theta)$ ——新旧策略的概率比;

$\hat{A}_t$ ——优势函数,衡量动作相对于平均策略的优劣;

ϵ ——超参数,控制剪切范围。

PPO根据优势函数的数值范围,限制 $r_t(\theta)$ 的范围,防止策略更新过大:当 $\hat{A}_t > 0$ 表明动作有利,限制 $r_t(\theta)$ 不超过 $1 + \epsilon$,避免过度放大优势;当 $\hat{A}_t < 0$ 表明动作不利,限制 $r_t(\theta)$ 不低于 $1 - \epsilon$,避免过度抑制劣势动作。

2.3 模型耦合机制

针对传统水力模型(如 SWMM)计算开销巨大、难以支撑 RL 大规模采样训练的局限性,本文构建了 1 种基于 TGNN-RL 的预测-决策耦合调度架构。该架构将 TGNN 集成为 RL 智能体交互的动态环境,通过数据驱动的方式实现水力状态预测与调度逻辑的深度耦合。

在 PPO 算法的执行循环中, TGNN 承担了环境状态预测的功能,包含降雨特征融入的耦合机制如下。

(1)真实观测输入。在每一控制时刻 t , 系统获取来自管网监测数据的真实节点和边的原始状态特征作为输入状态特征 s_t^{real} ;

(2)动作决策。RL 智能体基于 s_t^{real} , 并结合未来 1 个控制周期的降雨数据,通过当前策略网络 π_θ 输出控制动作 a_t ;

(3)单步状态预测与转移。TGNN 接收控制动作 a_t 及历史真实系统状态数据 $S = (s_t, s_{t-1}, \dots, s_{t-n})$, 并将单步预测时域内的降雨数据作为动态外部边界条件输入,持续执行前向推理,生成下一控制时刻 $t+1$ 的系统状态预测值 s_{t+1} , 此过程在逻辑上替代了传统水力模型的状态演进过程。

(4)奖励计算与策略更新。系统根据 s_{t+1} 中的内涝体积与溢流体积,通过奖励函数计算奖励 r_t 并更新策略。

3 智能调度模型训练

3.1 降雨与训练数据

使用的降雨数据通过芝加哥雨型公式生成。芝加哥雨型公式如式(6)~式(7)。

$$i(t_b) = \frac{A \times (1 + C \times \log P) \times \left(\frac{(1-n)t_b}{K} + b \right)}{\left(\frac{t_b}{K} + b \right)^{1+n}} \quad (6)$$

$$i(t_a) = \frac{A \times (1 + C \times \log P) \times \left(\frac{(1-n)t_a}{1-K} + b \right)}{\left(\frac{t_a}{1-K} + b \right)^{1+n}} \quad (7)$$

其中: $i(t_b)$ ——峰前雨强, mm/min;

$i(t_a)$ ——峰后雨强, mm/min;

t_b, t_a ——峰前时间、峰后时间, min;

A ——1 a 重现期时的 1 min 设计降雨量(与地区有关), mm;

C ——经验参数(与地区有关);

P ——重现期, a;

K ——时峰比, 决定雨峰出现的时刻;

n, b ——地区经验参数。

结合 H 市气候特点,该区域芝加哥雨型参数的取值如表 2 所示。

生成 40 场训练用降雨和 4 场测试用降雨(分别作为中小雨、中雨、中大雨、大雨代表),每场降雨历时 4 h,降雨数据频率为 1 min,各测试降雨信息如表 3 所示。

表 2 使用的芝加哥雨型参数
Tab. 2 Parameters of Chicago Rainfall Pattern

参数类型	取值
A/mm	21~35
C	0.93~1.20
P/a	1~5
K	0.3~0.8
n	0.86~0.96
b	16~22

表 3 测试降雨信息
Tab. 3 Information of Testing Rainfall

降雨	累积降雨量/mm
降雨 1	14.7
降雨 2	19.3
降雨 3	25.3
降雨 4	33.9

对于 40 场训练降雨,在每个控制生成时刻(基于预设的泵安全运行间隔)随机生成 7 台泵的启闭向量,每场降雨共生成 5 次,得到批量为 200 的管网运行数据用于训练该管网的时序图神经网络。对于 4 场测试用降雨,在每个控制生成时刻随机生成七台泵的启闭向量,每场降雨共生成 1 次,得到批量为 4 的管网运行数据,用于测试 TGNN 性能。

3.2 基于 TGNN 的排水系统运行状态预测

排水管网中的各种设施可以简化成图论中的节点和边,比如检查井、调蓄池、排放口等设施可以简化成节点,管段、泵等设施可以简化成边。这些简化后的节点和边仍含有原有设施的运行状态信息,通过充分利用节点和边的信息,即可实现良好的排水管网运行状态预测。基于简化后的图,排水管网运行状态预测问题可以简化成节点和边的预测问题。

使用的 TGNN 超参数设置如表 4 所示,训练以均方根误差为损失函数,采用 Adam 优化器调整学习率,初始学习率为 0.001,训练轮数为 100 轮。

表 4 TGNN 超参数设置
Tab. 4 Hyperparameter Settings of TGNN

参数	数值
网络层数	2
隐藏层维度	64
注意力头数	4
隐藏层 dropout	0.2
样本批量大小	64

本文使用的评价指标为平均绝对误差(M_{AE})、均方误差(M_{SE})、纳什系数(N_{SE}),其计算公式分别如式(8)~式(10)。

$$M_{\text{AE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$M_{\text{SE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$N_{\text{SE}} = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

其中: y_i ——真实标签;

$\hat{y}_i$ ——预测标签;

$\bar{y}$ ——真实标签的平均值。

3.3 基于 RL 的排水系统智能调度

3.3.1 状态空间

对于 RL 状态,选择 7 台泵的动作,2 个调蓄池的水深、1 个雨量计的瞬时雨强、5 个管段的流量、12 个检查井的水深、4 个排放口的入流量和 1 个污水处理厂的人流量作为状态,总共 32 个状态,主要为调蓄池、调蓄池上下游、管网起始端、管网交汇处、管网末端以及雨量计等关键位置的状态,以期让调度模型对整个管网的运行状态有充分感知。

状态空间表示如式(11)。

$$s_t = [a_{t-1}, l_{t-1}, q_{t-1}, I_t] \quad (11)$$

其中: s_t ——时刻 t 的状态向量;

a_{t-1} ——上一时刻动作向量;

l_{t-1} ——上一时刻监测点水深, m;

q_{t-1} ——上一时刻监测点流量, m^3/s ;

I_t ——当前时刻雨强, mm/min 。

3.3.2 动作空间

在每个时间步的决策动作为 7 台泵的启闭状态,其表示式如式(12)。

$$a_t = [a_{1,t}, a_{2,t}, a_{3,t}, a_{4,t}, a_{5,t}, a_{6,t}, a_{7,t}] \quad (12)$$

其中: a_t —— t 时刻动作 7 台泵的联合动作向量;

$a_{i,t}$ —— t 时刻动作 i 泵的启闭状态。

本文涉及 7 台泵的控制,并且泵开启使用 1 表示,关闭使用 0 表示,动作空间有 128 种动作,控制步长为 15 min。

3.3.3 目标与奖励

本文以实现 4 个排放口的 CSO 与整个管网的

内涝体积的总和的最小化为控制目标,其奖励函数表达如式(13)~式(15)。因为 RL 的训练目标是为了最大化累积奖励,通过奖励取负将最小化溢流与内涝体积的控制目标转换为 RL 训练目标。

$$R_{\text{CSO},t} = -\frac{Q_c}{Q_i} \quad (13)$$

$$R_{\text{flooding},t} = -\frac{Q_f}{Q_i} \quad (14)$$

$$R_t = -\frac{Q_c + Q_f}{Q_i} \quad (15)$$

其中: $R_{\text{CSO},t}$ —— t 时刻的 CSO 奖励;
 $R_{\text{flooding},t}$ —— t 时刻的内涝奖励;
 R_t —— t 时刻的总奖励;
 Q_c ——当前时间步内 4 个排放口的出流体积之和, m^3 ;
 Q_f ——当前时间步内整个管网的内涝体积, m^3 ;
 Q_i ——当前时间步内整个管网的人流体积, m^3 。

3.3.4 约束条件

对调蓄池的运行液位设置约束,调蓄池 CC 的最大深度为 2.3 m,要求运行液位 ≤ 2 m;调蓄池 JK 的最大深度为 5.8 m,要求运行液位 ≤ 5.3 m。约束表达式如式(16)~式(17)。

$$p_{i,t} = \begin{cases} 0 & \text{if } h_{i,t} \leq L_{\text{lim}} \\ -0.1 & \text{else} \end{cases} \quad (16)$$

$$p_t = \sum_{i=1}^n p_{i,t} \quad (17)$$

其中: p_t ——时刻 t 所有调蓄池液位越限的总惩罚;
 $p_{i,t}$ ——时刻 t 第 i 个调蓄池液位越限惩罚;
 $h_{i,t}$ ——每一时刻运行液位,m;
 L_{lim} ——调蓄池运行液位最大限制值,m。
此时的奖励函数表达式如式(18)。

$$R_t = R_{\text{CSO},t} + R_{\text{flooding},t} + p_t = -\frac{Q_c + Q_f}{Q_i} + \sum_{i=1}^n p_{i,t} \quad (18)$$

3.3.5 超参数

RL 模型基于 PPO 搭建,各超参数的设置如表 5 所示。

表 5 RL 模型超参数设置

Tab. 5 Hyperparameter Settings of RL Model

参数名称	数值
裁剪比	0.2
学习率	0.000 01
折扣因子	0.99
广义优势估计参数	0.95
ε -探索初始值	0.1
ε -探索衰减值	0.99

4 结果分析

4.1 排水系统运行状态预测

整体上看,模型在测试降雨事件中的 M_{AE} 为 0.016 5、 M_{SE} 为 0.006 4、 N_{SE} 为 0.999 9,4 场测试降雨中 TGNN 对管网运行状态变化趋势的预测结果 N_{SE} 均极为接近 1。这是因为管网规模较小,拓扑结构简单,单步预测由于输入包含了上一时刻的真实状态(SWMM 水力模型模拟数据),模型能够实现高精度的映射。在不依赖实时真值反馈的情况下滚动预测, N_{SE} 降至 0.998 2,证明模型并非简单的记忆数据。

局部上,对测试降雨 2 中调蓄池 JK、排放口 CC-1、泵 JK-R1 的预测结果如图 2 所示,TGNN 对每个量的预测误差都很低,具有高准确性、低滞后




图 2 测试降雨 2 中部分调蓄池、排放口和泵的预测结果

Fig. 2 Prediction Results for Selected Storage Tank, Outfall, and Pump in Test Rainfall 2

性,仅在突发急剧波动和部分持续时间较长的小波动情况下预测误差相对增大。这表明 TGNN 能够有效、准确地预测排水管网的运行状态。

本文使用计算设备为 1 台 NVIDIA GeForce RTX 4090 GPU、1 台 AMD EPYC 9734 112-Core Processor 型 CPU 服务器, TGNN 单步 5 min 预测计算开销仅为 0.000 2 s, 计算效率约为 SWMM 水力模型模拟的 25 倍, 在计算效率上具有显著优势。

4.2 排水系统智能调度

本文训练了不考虑运行约束与考虑运行约束的智能调度模型(分别简称“RL”、“RL-Cst”), 用于最小化累积溢流与内涝。这两个模型的训练奖励变化如图 3 所示, 经过 3 500 轮训练后模型已充分收敛。




图 3 强化学习模型训练奖励曲线

Fig. 3 Training Reward Curve of RL Model

表 6 展示的是 RL、RL-Cst 和基于规则的控制 RBC 3 个模型在各测试降雨中调蓄池 CC、JK 的运行液位满足率。从液位满足率看, RL-Cst 和 RBC 调

度模型在各雨况中均能满足最大运行液位约束, 而 RL 由于训练时未考虑运行约束限值, 所以其在输出调度策略时未考虑运行液位变化。这也表明经过充分训练后, 考虑了运行液位约束的强化学习模型可以制定满足运行液位约束的调度决策。

表 6 各测试降雨中调蓄池运行液位满足率

Tab. 6 Satisfaction Rates of Storage Tank Operation
Water Levels under Each Test Rainfall

调蓄池	RL		RL-Cst		RBC	
	CC	JK	CC	JK	CC	JK
降雨 1	100%	94.5%	100%	100%	100%	100%
降雨 2	100%	100%	100%	100%	100%	100%
降雨 3	100%	100%	100%	100%	100%	100%
降雨 4	66.4%	97.1%	100%	100%	100%	100%

RL、RL-Cst、RBC 3 个模型在各测试降雨中的控制效果如图 4 所示。经过系统训练后, 模型已充分学习排水系统的动态特征, 能够提出以最小化溢流量与内涝体积为目标的优化控制策略。在 4 个测试降雨事件中, RL、RL-Cst 的控制效果均优于 RBC, RL-Cst 的总体积仅为 RBC 的 40%~67%, 其中测试降雨 1 中 RL-Cst 的总体积为 1 988 m³, 相较于 RBC 总体积 2 982 m³ 削减最少; 测试降雨 2 中 RL-Cst 的总体积为 1 592 m³, 相较于 RBC 总体积 4 029 m³ 削减最多。RL 对总体积的削减效果均稳定在 50% 以上。对比 RL 和 RL-Cst, RL 对总体积的削减效果均强于 RL-Cst。然而, 内涝控制显示 RL-Cst 在测试降




图 4 RL、RL-Cst、RBC 模型控制效果对比

Fig. 4 Comparison of Control Performance among RL, RL-Cst, and RBC Models

雨 1~3 中均优于 RL,这表明 RL-Cst 为了在实现控制目标的同时兼顾满足液位运行约束,主要以增加溢流量的方式实现这 2 个目的。在测试降雨 4 中 RL 的内涝体积约为 RL-Cst 的 89%,RL-Cst 稍逊于 RL,因为此时降雨强度大,泵站没有足够的溢流泵可以利用,导致内涝体积增大。

4.3 监测数据稀疏对智能调度模型的影响

排水管网建模与调度一般需要位于检查井、管段、泵站等管网设施中的液位计、流量计等监测设备的数据辅助校核管网、监测管网实时运行状态,以便后续排水管网调度。但在实际排水管网中,受建设不充分、设备故障等因素影响,监测数据往往具有一定的稀疏性。

为了探究监测数据稀疏时对智能调度模型的影响,仅在少部分节点和管道进行监测设施布置。监测设施布置方案(简称 M)如表 7 所示。

表 7 监测布置方案 M

Tab. 7 Monitoring Layout Scheme M

监测布置方案	使用节点数量与占比	使用边数量与占比
仅在泵、调蓄池、入流检查井、起始检查井、排放口、调蓄池上游管道布置监测	27 个;22%	9 条;7%

分别测试使用时序图神经网络和所有节点和管道特征训练的智能调度模型 TGNN-RL、使用 SWMM 和所有节点和管道特征训练的智能调度模型 SWMM-RL 和使用时序图神经网络和监测布置方案 M 训练的智能调度模型 TGNN-RL(z)。因监测布置方案 M 仅监测少数节点,故以最小化溢流体积作为训练优化目标。

TGNN-RL、TGNN-RL(z) 相对于基于水力模型的 SWMM-RL 的溢流量误差如表 8 所示,从相对误差来看,TGNN-RL 与 TGNN-RL(z) 在所有降雨场景中均能与 SWMM-RL 保持较高的结果一致性,其相

表 8 TGNN-RL、TGNN-RL(z) 相较于 SWMM-RL 的溢流量误差

Tab. 8 Overflow Volume Errors of TGNN-RL and TGNN-RL(z) Relative to SWMM-RL

降雨	TGNN-RL 相对误差	TGNN-RL(z) 相对误差
1	2.5%	2.5%
2	5.7%	5.6%
3	2.7%	2.8%
4	1.7%	1.8%

对误差均较小(1.7%~5.7%),表明 TGNN 能够较好的预测排水系统运行状态。三者溢流控制效果对比如图 5 所示,结合误差和控制效果来看,仅使用 22%节点和 7%边监测数据的 TGNN-RL(z) 与使用所有节点和边监测数据的 TGNN-RL 溢流控制效果相近,二者相对误差在 $\pm 1\%$,溢流控制线基本重合。这表明智能调度模型在面临监测数据稀疏时仍能够有效预测调度,具有较好的鲁棒性。




图 5 TGNN-RL、TGNN-RL(z) 与 SWMM-RL 溢流控制效果对比

Fig. 5 Comparison of Overflow Control Performance among TGNN-RL, TGNN-RL(z) and SWMM-RL Models

5 结论与展望

本文围绕合流制排水管网运行状态预测与智能调度展开,构建并验证了耦合 TGNN 与 RL 的智能调度方法,主要结论如下。

(1)TGNN 显著突破了传统水力模型的计算瓶颈。TGNN 在保持高精度预测的同时,将计算效率提升了约 25 倍。这证明了深度学习模型在排水管网数字化孪生与实时预演中的巨大潜力。

(2)基于 RL 的排水系统智能调度模型能够以内涝和溢流总体积最小化为目标进行实时控制。此外,通过调整运行水位约束,揭示了系统安全与运行效能之间的权衡逻辑;考虑运行水位约束的调度模型更偏好管网安全运行;未考虑运行水位约束的模型则能更好地削减内涝与溢流总体积。

(3)耦合 TGNN 与强化学习的智能调度模型展现出良好的实用性与鲁棒性。该模型在监测数据稀

疏的情况下仍能保持稳定的调控效果且性能与基于SWMM水力模型的调度方案相近。这表明该方法能够有效应对实际工程中传感器缺失或故障的挑战,具有良好的可行性和前景。

本文提出的智能调度方法仍有不足之处,未来将围绕以下方面进一步深化拓展。

(1)构建预测误差的反馈与补偿机制。当前模型主要基于TGNN的预演状态进行决策,尽管真值输入的单步预测和RL环境闭环交互具备一定的自我修正能力,但尚未量化评估预测误差对复杂决策路径的扰动。未来可引入在线残差补偿或不确定性量化算法,以增强调度方案在极端预测偏差下的可靠性与安全性。

(2)深化多元数据异常下的鲁棒性压力测试。虽然模型在现有稀疏场景下表现稳健,但实际工程中传感器失效模式较为复杂(如关键节点丢失,长时序数据漂移等)。后续研究需开展异质性数据缺失的模拟实验,探索模型在信息极度匮乏条件下的性能边界。

(3)探索大尺度、高复杂度排水系统的泛化性与协同调度。研究区域(面积为27.65 km²)相对集中,对于超大城市尺度下的降雨空间异质性模拟尚显不足。此外排水管网拓扑简单,随着管网拓扑复杂度的指数级提升,TGNN在大规模图结构上的计算效率与收敛性仍需进一步验证。

参考文献

- [1] 陈帅,舒启瑞,陈小龙. 城市排水系统智能控制与调度研究[J]. 给水排水, 2024, 50(7): 155-161.
Chen S, Shu Q R, Chen X L. Research on intelligent control and scheduling of urban drainage system [J]. Water & Wastewater Engineering, 2024, 50(7): 155-161.
- [2] 陈泽伟,纪莎莎,何黎,等. 基于水动力模型与大数据分析的污水干线优化调度策略[J]. 净水技术, 2024, 43(3): 110-116.
Chen Z W, Ji S S, He L, et al. Optimized controlling strategy of wastewater trunk pipelines based on hydrodynamic model and big data analysis[J]. Water Purification Technology, 2024, 43(3): 110-116.
- [3] Aderyani F R, Mousavi S J. Machine learning-based rainfall forecasting in real-time optimal operation of urban drainage systems[J]. Journal of Hydrology, 2024, 645: 132118. DOI: 10.1016/j.jhydrol.2024.132118.
- [4] El Ghazouli K, El Khatabi J, Soulhi A, et al. Model predictive control based on artificial intelligence and EPA-SWMM model to reduce CSOs impacts in sewer systems[J]. Water Science and Technology, 2022, 85(1): 398-408.
- [5] Cembellín A, Francisco M, Vega P. Distributed model predictive control applied to a sewer system[J]. Processes, 2020, 8(12): 1595. DOI: 10.3390/pr8121595.
- [6] Cembellín A, Francisco M, Vega P. Optimal operation of a benchmark simulation model for sewer networks using a qualitative distributed model predictive control algorithm[J]. Processes, 2023, 11(5): 1528. DOI: 10.3390/pr11051528.
- [7] Garzón A, Kapelan Z, Langeveld J, et al. Machine learning-based surrogate modeling for urban water networks: Review and future research directions[J]. Water Resources Research, 2022, 58(5): e2021WR031808. DOI: 10.1029/2021WR031808.
- [8] 涂伟,池向沅,赵天鸿,等. 城市排水管网流量预测多视图时空图神经网络模型[J]. 测绘学报, 2025, 54(2): 334-344.
Tu W, Chi X Y, Zhao T H, et al. Multi-view spatio-temporal graph convolutional networks model for urban drainage networks flow prediction[J]. Acta Geodaetica et Cartographica Sinica, 2025, 54(2): 334-344.
- [9] Gogien F, Dechesne M, Martinerie R, et al. Is an artificial neural network (ANN) a reliable alternative to distributed models for combined sewer overflow (CSO) simulation? [J]. Journal of Hydroinformatics, 2025, 27(5): 805-822.
- [10] Ren H C, Pang B, Zhao G, et al. Incorporating dynamic drainage supervision into deep learning for accurate real-time flood simulation in urban areas[J]. Water Research, 2025, 270: 122816. DOI: 10.1016/j.watres.2024.122816.
- [11] Li M R, Shi X M, Lu Z M, et al. Predicting the urban stormwater drainage system state using the Graph-WaveNet[J]. Sustainable Cities and Society, 2024, 115: 105877. DOI: 10.1016/j.scs.2024.105877.