

DOI: 10.14042/j.cnki.32.1309.2025.05.012

基于图网络代理模型的城市排水系统智能控制

周楚天¹, 刘攀¹, 许钦^{2,3}, 谢康^{2,4}, 蔡晶^{2,5}

(1. 武汉大学水资源工程与调度全国重点实验室, 湖北 武汉 430072; 2. 南京水利科学研究院水灾害防御全国重点实验室, 江苏 南京 210029;
3. 长江保护与绿色发展研究院, 江苏 南京 210098; 4. 水利部应对气候变化研究中心, 江苏 南京 210029;
5. 皖江工学院, 安徽 马鞍山 243031)

摘要: 为针对城市排水系统实时控制中模拟精度与控制效率难以兼顾的问题, 本文提出了一种结合图神经网络代理模型与强化学习的智能实时控制方法, 以提升溢流风险管控效能。构建了可高效模拟复杂系统溢流的图神经网络代理模型; 以溢流最小化为目标、代理模型为虚拟环境, 采用强化学习实现多闸门动态调控。以岳阳市排水片区为例开展研究, 结果表明: 代理模型测试期内纳什效率系数达到 0.969, 模拟精度较高; 强降雨条件下, 基于代理模型的强化学习策略最大可削减 18.1% 的溢流量, 且单步决策仅用 0.19 s, 显著优于遗传算法等传统方法(单步耗时 16.2 min); 在不确定性情景下, 强化学习更加稳健。研究可为城市排水系统智能调控提供技术支撑。

关键词: 城市排水系统; 图神经网络; 代理模型; 城市内涝; 实时调控; 智能控制

中图分类号: TU992.4 **文献标志码:** A **文章编号:** 1001-6791(2025)05-0857-12

城市排水系统主要负责城市废水及雨水径流的收集与排放, 承担着保障城市排涝、防治内涝和维护城市环境的重要职责^[1-2]。排水系统不仅是城市可持续发展的关键组成部分, 其运行效率和服务水平也与城市的繁荣与扩展密切相关^[3]。在全球气候变化的背景下, 如何提升排水系统的运行效率以减少内涝风险^[4]成为亟需解决的重要挑战。

城市排水系统的实时控制是实现溢流削减的重要手段。通过对系统运行状态的实时监测与分析, 制定动态调整控制策略, 以提升排水系统的整体运行效率^[5]。目前, 实时控制方法主要分为启发式控制和基于优化的控制两大类。启发式控制(如规则控制与模糊逻辑控制)主要依靠专家经验, 通过 IF-THEN 规则^[6]或模糊推理^[7]实现系统状态与控制动作的关联。其实现简便、对模型依赖性低, 在实际工程中应用广泛, 但也存在着难以保证最优、复杂系统中规则繁多灵活性不足^[8]等问题。相较之下, 基于优化的控制方法依托动力学模拟, 并结合预设目标与约束, 采用线性二次控制、模型预测控制与智能优化算法等^[9], 系统地求解最优控制策略, 能更有效地提升溢流削减和系统调控效果。近年来, 强化学习等基于机器学习的智能控制方法通过与环境的交互自主学习控制策略, 展现了优于传统方法的适应性和实时性^[10]。然而, 这些控制方法普遍依赖与动力学模型大量交互进行系统仿真, 随着排水系统的结构和运行复杂度不断提升, 模型模拟所需计算资源 and 时间大幅增加^[11-12], 从而严重制约了实时控制策略的时效性与实际应用。

代理模型的引入为提升排水系统模拟效率提供了新思路^[13]。代理建模作为一种抽象建模方法, 旨在开发和利用相较于“原始”仿真模型计算成本更低的“替代体”, 以提升模拟效率。目前, 机器学习是城市排水系统代理模型中应用最为广泛的方法^[11], 在排水系统的设计优化^[14]、实时运行管理与调度^[15], 以及弥补过程模

收稿日期: 2025-08-11; 网络出版日期: 2025-11-03

网络出版地址: <https://link.cnki.net/urlid/32.1309.P.20251031.1847.002>

基金项目: 国家自然科学基金项目(52209031; U2443202)

作者简介: 周楚天(1998—), 男, 江苏盐城人, 博士研究生, 主要从事智慧城市排水系统方面研究。

E-mail: zct1998@whu.edu.cn

通信作者: 刘攀, E-mail: liupan@whu.edu.cn

型在精度和适用性不足等方面^[16]，均展现出显著的应用价值。然而，这些方法多将系统视为无空间结构的“黑箱”，忽略了排水管网复杂的空间拓扑关系与节点间的水力动态耦合，限制了模型的物理解释性和对多变工况的泛化能力。图神经网络作为一种专门用于处理图结构数据的深度学习框架，能够在保留网络拓扑的同时跨节点传递和聚合特征，刻画空间邻近与动态交互机制。在水文水资源领域，图神经网络已成功应用于河网洪水预报、水位预测等任务^[17-18]，显著提升了模型精度与可解释性，但其在城市排水系统代理建模中的应用潜力尚未充分挖掘。

本文将基于图神经网络的高精度代理模型与强化学习优化决策相结合，提出一种能够兼顾模拟精度与优化效率的城市排水系统智能调控新方法。以湖南省岳阳市典型排水片区为应用案例，开展城市排水系统的高效模拟与智能调控研究。

1 研究区域

以湖南省岳阳市中心城区的洛王路排水片区为案例区域。如图 1 所示，研究区面积为 2.04 km²，排水系统为合流制管网，包括 275 条管道、270 个检查井和 1 座调蓄池。调蓄池容量为 2 万 m³，暴雨时可临时储存多余污水，并通过泵站输送至污水厂。当调蓄池满且泵站输送能力不足时，剩余污水会排入附近河流，造成污染。在实际运行中，降雨是影响排水系统运行的主要外部因素，因此主要关注降雨事件对系统的影响。为提升调蓄效率，研究区在管网关键节点设置了 3 个流量控制设施，通过实时闸门调节实现动态分配流量，缓解暴雨期间的溢流压力。研究区域已建立经过校准的雨水管理模型 (Storm Water Management Model, SWMM)，并经过实际内涝过程检验^[11,19]。




图 1 研究区排水设施分布
Fig. 1 Drainage facilities distribution of the study area

2 研究方法

针对城市排水系统调控在精度与效率上的双重挑战，研究构建了“代理建模-智能控制”协同框架

(图 2)。基于图神经网络方法开发排水系统的高精度代理模型，用以快速、准确地模拟系统在不同工况下的动态响应。以该代理模型为环境，引入强化学习算法学习多闸门的最优实时控制策略，实现溢流风险最小化的智能调度。




图 2 方法框架

Fig. 2 Schematic diagram of methodology

2.1 基于图神经网络的城市排水系统代理模型

采用图神经网络代理模型，将输入和输出数据以图结构的形式进行组织。城市排水系统可以抽象为无向图表示^[20]，其中节点对应排水系统中的检查井，边对应各个管道。图神经网络善于处理不规则的图结构数据，利用拓扑信息提升代理模型的模拟精度。

2.1.1 代理模型输入与输出

代理模型输入为节点的降雨入流、闸门的控制状态(考虑全开、半开和全关 3 种状态)以及排水系统的图结构,输出为所有管道的流量序列。由于一些节点长期处于零溢流状态,若直接以溢流量为目标建立代理模型,将会导致样本中零溢流数据占据较大比例,引发数据不平衡问题,影响模型性能^[21]。因此,采用水量平衡原理推求溢流量,即每一个节点应满足节点的入流总量与出流总量之差等于该节点的溢流量。

2.1.2 模型架构

如图 2 所示,研究提出了一种结合图神经网络与序列学习机制的编码器-解码器(Encoder-Decoder)模型框架^[22]。输入数据包括降雨入流、闸门动作与排水系统拓扑结构。其中,降雨入流以节点属性形式嵌入排水系统节点表,闸门动作以边权重形式嵌入边索引表。数据首先经嵌入(Embedding)层处理,得到低维稠密的特征表示。编码器由图注意力卷积层(GATConv)^[23]、门控循环单元(GRU)和注意力机制(Attention)顺序组成,同时捕获空间结构关联(节点-管道网络结构)与时间动态(降雨序列-流量序列)^[17]。解码器包括掩码注意力机制(Masked Attention)、注意力机制以及图注意力卷积层,强化时序建模与空间特征提取。图注意力卷积层基于邻接矩阵注意力权重实现节点特征聚合;门控循环单元沿时间维度对特征进行序列建模;注意力机制为关键时间片分配动态权重生成上下文向量;编码器与解码器通过隐状态传递融合空间与时间特征;最终经全连接层回归管道流量。

2.1.3 训练数据

根据宋晓猛等^[24]研究成果,造成城市内涝问题的一般为短历时、高强度降雨。根据岳阳市气象局提供的 2014—2020 年实测降雨数据进行 SWMM 模拟,为丰富训练数据,对长历时强降雨进行分割,以溢流总量大于 1 000 m³ 为标准筛选,共得到 421 场 3 h 致涝降雨过程。降雨数据输入至 SWMM 中,生成所需要的样本数据进行模型训练,每样本历时为 4 h,包括 3 h 降雨过程与 1 h 排水过程。为提升模型的泛化能力,每一场致涝降雨生成 20 组不同的闸门控制策略,各控制时段下闸门动作均为随机生成,最终得到 8 420 例样本。由于数据较丰富,以 7:2:1 的比例划分为训练集、验证集和测试集^[11]。

2.1.4 损失函数与评价指标

训练过程中采用均方误差(E_{MS})指标构建损失函数。此外,考虑到代理模型面向闸门控制的应用场景,还应关注闸门位置处的模拟流量以提升模型效果。损失函数(L)的具体表达形式如下所示:

$$L = \sum_{k=1}^K \sum_{t=1}^T \frac{(q_{k,t} - \hat{q}_{k,t})^2}{KT} + \sum_{i=1}^I \sum_{t=1}^T \frac{(q_{i,t} - \hat{q}_{i,t})^2}{T} \quad (1)$$

式中: q 为 SWMM 模拟流量; $\hat{q}$ 为代理模型模拟流量; k 为管道编号, $k=1, 2, \dots, K$; i 为闸门编号, $i=1, 2, \dots, I$; t 为模拟时段, $t=1, 2, \dots, T$ 。在模型训练过程中,采用网格搜索法确定超参数,采用 Adam 优化器进行参数更新^[25],学习率设定为 0.002。

对于时间序列模拟问题,采用纳什效率系数(E_{NS})作为评价指标^[26],采用均方根误差(E_{RMS})评价溢流代理效果。

2.2 基于强化学习的实时控制模型

研究采用强化学习方法,实现城市排水系统实时控制以削减溢流。强化学习是一种通过智能体与环境不断交互、基于奖励反馈学习最优决策的机器学习方法^[27]。研究将代理模型建模为强化学习环境,智能体根据模型当前状态选择控制动作(闸门开度调节),所选动作输入代理模型环境,获得下一时刻的状态及奖励。通过与环境的多轮交互,智能体不断调整策略以最大化长期累计奖励,从而实现对溢流风险的有效控制。

2.2.1 强化学习设置

强化学习环境是由城市排水系统代理模型与不同降雨过程构成, 智能体产生的动作作用于代理模型中, 奖励函数的计算也基于代理模型输出值。

状态空间描述城市排水系统在任一时刻的运行状态, 研究系统状态(s_t)可表示为

$$s_t = \left[\frac{V_{\text{fl},t-1}}{V_{\text{in},t-1}}, \mathbf{a}_{t-1}, \mathbf{e}_{t-1}, P_t \right] \quad (2)$$

式中: $V_{\text{fl},t-1}$ 为上一时段溢流量; $V_{\text{in},t-1}$ 为上一时段入流总量; $\mathbf{a}_{t-1}$ 为上一时段动作向量(闸门开度控制); $\mathbf{e}_{t-1}$ 为上一时段控制节点上游管道充满率向量; P_t 为当前时段降水量。

动作空间描述强化学习智能体在决策时刻可采取的控制措施, 由排水系统内3个闸门的开度调节组成。动作空间($\mathbf{a}_t$)记为

$$\mathbf{a}_t = [g_{1,t}, g_{2,t}, g_{3,t}] \quad (3)$$

式中: $g_{i,t}$ 为第*i*个闸门在时段*t*的开度, $i=1,2,3$ 。实际工程中, 过于高频与细化的闸门动作会导致机械磨损增加、故障率提升等问题^[9], 本研究设置控制动作间隔为20 min, $g_{i,t}$ 取值为{0, 0.5, 1}, 对应闸门全关、半开与全开。

奖励是强化学习的重要组成部分。强化学习模型为多步决策过程, 需要考虑每步决策对于后续决策的影响。若采用溢流总量与峰值削减率等整体指标, 则多步过程内仅存在一次奖励反馈, 不利于模型收敛。同时, 奖励应以比值形式表达, 归一化处理以消除不同强度事件的影响。因此, 奖励函数设置为排水系统当前时段溢流量与入流量之比, 定义如下:

$$R_t = -\frac{V_{\text{fl},t}}{V_{\text{in},t}} \quad (4)$$

该奖励函数能够直接反映排水系统的溢流控制效果, 溢流比例越低, 奖励值越高(负值越小)。

2.2.2 强化学习算法

研究采用近端策略优化(Proximal Policy Optimization, PPO)算法^[28]训练强化学习智能体。PPO算法的核心思想是通过限制每次策略更新的幅度, 避免策略发生剧烈变化, 从而提升训练稳定性和样本利用效率。PPO采用“剪切概率比”机制, 具体目标函数如下:

$$L_{\text{CLIP}}(\theta) = \mathbb{E}_t \left[\min \left(r_t(\theta) \widehat{A}_t, \text{clip}(r_t(\theta), 1-\epsilon, 1+\epsilon) \widehat{A}_t \right) \right] \quad (5)$$

式中: $r_t(\theta)$ 为新旧策略对当前动作的概率比; $\widehat{A}_t$ 为优势函数, 采用广义优势估计计算, 衡量当前动作相对于平均水平的优劣; ϵ 为超参数, 控制剪切的范围; $\text{clip}(x, 1-\epsilon, 1+\epsilon)$ 表示将概率比限制在指定区间内; $\mathbb{E}_t$ 表示对采样数据取经验期望。

具体训练流程如图2所示。PPO训练超参数采用网格搜索法确定, 剪切系数为0.2, 广义优势估计平滑参数为0.95, 折现因子为0.99, 每批次采样数为120, 学习率为0.002。

2.3 对比方案

为验证所提方法的有效性, 设计了3种控制方案进行对比:

(1)静态排水。城市排水系统主要属于无压流系统。在静态排水工况下, 所有闸门均保持完全开启, 系统依靠重力作用实现排水过程。静态排水作为基准值用于评价其他调控方案的效果。

(2)规则控制。在规则控制方式下, 闸门的开度由预先设定的IF-THEN规则决定, 仅依赖于系统状态。当控制闸门节点未发生溢流时, 闸门开度设为开启; 当控制闸门上游管道未满足且控制闸门节点发生溢流

时，闸门开度设为关闭。

(3)基于遗传算法的优化控制。为对比强化学习方法的性能，引入遗传算法作为城市排水系统优化控制方法。遗传算法是一类基于自然选择和遗传机制的全局优化方法，能够在复杂、高维、非线性的问题空间中搜索最优解^[29]。在本研究中，每一个个体表示所有闸门在控制周期内的开度序列。种群通过遗传操作不断进化，目标是最小化城市排水系统溢流风险。

考虑到代理模型可能引入的模拟误差，静态排水与规则控制方案直接在 SWMM 上执行，遗传算法与强化学习则依托代理模型完成优化计算，随后将优化得到的控制策略输入 SWMM 进行评估。

3 结果与讨论

3.1 代理模型精度

代理模型训练期、验证期与测试期溢流模拟效果如图 3(a)—图 3(c)所示。可以发现，训练、验证与测试期间评价数据非常接近， E_{NS} 指标表现较好。这表明模型未出现明显的过拟合现象，可以用于未知数据的模拟任务。模型溢流流量模拟值与真实值之差集中在 0~10 之间，呈现略微的正偏差，这是由于深度学习的特性导致不能完美模拟溢流量为 0 的情景，对实际应用的影响很小。此外，图 3(d)展示了各节点处溢流代理结果，节点溢流平均 E_{RMS} 为 0.03，最大不超过 0.10，这表明提出的水量平衡方法可以有效地计算溢流。




图 3 代理模型训练效果
Fig. 3 Performance of the surrogate model training

为进一步验证代理模型模拟溢流量的准确性，研究选取了 $P=50\%$ 、 $P=33\%$ 与 $P=20\%$ 的 3 h 设计降雨过程，SWMM 与代理模型输入同样随机产生的闸门控制动作，绘制动作下的溢流流量过程序列。如图 4 所示，代理模型能很好地模拟排水系统在不同降雨过程下的溢流流量序列过程， E_{NS} 指标较好。可见，本文所提出的图神经网络代理模型在各类降雨情景下均展现出优异的模拟精度，为后续排水系统智能控制提供了可靠模型。




图4 代理模型应用验证

Fig. 4 Application validation of the surrogate model

3.2 强化学习控制结果

3.2.1 强化学习训练结果

采用 PPO 算法对强化学习调控模型进行训练, 最终训练过程如图 5 所示。可以发现, 在训练初期, 奖励函数值呈现出波动上升态势, 表明模型在这一阶段通过不断学习, 策略得到了有效优化。当训练至一定程度后, 奖励值的增长放缓, 最终趋于平稳, 即模型已基本收敛。采用 PPO 强化学习的城市排水系统实时控制模型在训练过程中展现出了良好的收敛性与稳定性, 可以应用于后续的优化调控。

3.2.2 设计降雨下控制效率

表 1 对比了 3 h 设计降雨下不同控制策略的溢流削减能力, 其中相对提升指不同策略削减溢流量与静态控制总溢流量之比。可以看到强化学习表现最佳: 在 $P=50\%$ 的设计降雨下, 强化学习方法与遗传算法溢流削减能力几乎相同; 当设计频率为 $P=33\%$ 时, 3 种控制策略的相对提升幅度有所下降, 但仍保持相似的性能排序; 在更高强度的 $P=20\%$ 暴雨事件中, 各方案效果进一步减弱, 规则控制几近失效, 强化学习仍具备一定调控能力, 优于遗传算法。




图5 强化学习训练过程

Fig. 5 Reinforcement learning training process


图 6(a)—图 6(b)绘制了 $P=50\%$ 设计降雨情景下不同方案的溢流控制过程。从图 6 中可以看到, 规则控

制的溢流削减能力主要集中在最后时刻内。由于下游控制点一直处于溢流状态，闸门关闭，上游承担了蓄水任务，因此在最后时刻削减了可能的溢流。遗传算法与强化学习则是不同的控制取向。基于全局优化，遗传算法更平坦化溢流过程，强化学习智能体则基于状态信息做出即时响应，雨势加大时迅速排放缓解压力，减弱时又倾向蓄水，形成多峰态势。此外，由于奖励函数在多步控制期内累积，导致一些峰值影响被均化。图 6(c)展示了强化学习调控前后的溢流分布情况，其中调蓄池附近溢流量最大，通过强化学习调控可以有效削减。其他溢流点位基本被控制，偶有新的溢流点，但强度较低。


表 1 不同控制方案效果对比

Table 1 Comparison of the effects of different control methods


控制策略	P=50%		P=33%		P=20%	
	总溢流/万m ³	相对提升/%	总溢流/万m ³	相对提升/%	总溢流/万m ³	相对提升/%
静态控制	3.035	—	5.095	—	6.969	—
规则控制	2.795	7.9	4.835	5.1	6.934	0.5
遗传算法	2.565	15.5	4.555	10.6	6.697	3.9
强化学习	2.552	15.9	4.484	12.0	6.578	5.6



(a) P=50% 设计降雨下溢流控制过程



(b) P=50%设计降雨下闸门开闭过程



(c) P=50% 设计降雨下强化学习调控溢流分布

图 6 P=50% 设计降雨下溢流控制过程

Fig. 6 Overflow control processes under P=50% design rainfall event

对比不同模型与控制方法下的耗时，在相同滚动优化时段设置下，基于 SWMM 的遗传算法达到收敛平均耗时为 16.2 min，效率较低；而采用代理模型后，遗传算法的优化耗时显著缩短，仅为 62.40 s，充分体现了代理模型在提升优化效率方面的优势。进一步地，将代理模型与强化学习方法结合，滚动优化单步用时缩短至 0.19 s，速度较遗传算法提升了 328 倍。基于“代理建模-智能控制”的协同框架能够兼顾模拟精度与优

化效率, 实现了对城市排水系统调控问题的高效优化。

3.2.3 降雨强度对控制效率的影响

为探究方案在不同降雨过程下的调控能力, 研究采用 421 场至少造成 $1\,000\text{ m}^3$ 溢流的降雨过程作为输入进行调控, 结果如图 7 所示。可以发现, 3 种方案的控制效果随着降雨强度的增加而下降。在平均雨强为 9 mm/h 时, 3 种调控方法几乎可以做到完美调控, 将溢流量削减为 0 m^3 。当平均雨强达到 20 mm/h 以上时, 规则控制甚至出现负优化, 效果劣于静态排水。这主要是由于简单规则面临强降雨时不能充分利用排水系统空间, 易出现错误操作导致积水更为严重。当雨强较低时, 遗传算法的调控策略优于强化学习, 当雨强提升时, 强化学习适应性更强, 削减能力优于遗传算法。当平均雨强达到 20 mm/h 以上时, 3 种控制方案最优也仅能削减约 5% 的总溢流量。由于此时降雨强度已基本等同于或超过 5 年一遇的设计降雨强度, 显著超出了现有排水系统的设计能力, 在这种极端降雨下, 排水系统已接近或达到极限工况, 系统的溢流量主要受降雨强度主导, 调控措施对溢流的削减作用变得极为有限。此时, 防控重点应转向应急响应和极端条件下的快速排涝, 实施增加泵排、建立分洪区等应急调度策略。




图 7 降雨强度对总溢流削减率的影响

Fig. 7 Effect of rainfall intensity on the total overflow reduction rate

3.2.4 降雨不确定性对控制效率的影响

图 8(a) 展示了遗传算法与强化学习在降雨不确定下的表现。降雨不确定性采用高斯噪声进行刻画^[29], 相对误差满足正态分布 $N(0, \sigma^2)$ 。代理模型输入为 20 次加入误差的 3 h 设计降雨过程, 重现期为 $P=50\%$ 。结果表明降雨不确定性对总溢流削减率产生负面影响, 但强化学习稳健性更好, 削减能力优于遗传算法。从分布形态看, 强化学习的四分位距小于遗传算法, 对输入扰动更具鲁棒性。虽然降雨入流存在误差, 但强化学习可通过状态空间的反馈自适应调整策略, 使表现更为稳健。相较之下, 遗传算法以开环时序为决策单元, 易受外界扰动影响而偏离优化解。

3.2.5 控制间隔对控制效率的影响

图 8(b) 展示了遗传算法与强化学习在不同控制时间步长下的表现, 输入基于 $P=50\%$ 的 3 h 设计降雨过程。遗传算法结果基于 20 次优化均值, 强化学习则为确定性模型。结果表明随着控制时间步长缩短, 二者

优化效果均有提升，但强化学习表现更优，且在不同控制时间步长下更为稳定，这可能是由于控制时间步长的缩短提升了遗传算法求解的空间复杂度，导致算法易陷入局部最优。整体来看，强化学习方法在不同控制间隔下均展现出更优的效果和更强的稳定性，表明其在城市排水系统滚动优化中具有更大的应用潜力。




图 8 降雨不确定性与控制时间步长对总溢流削减率的影响

Fig. 8 Effect of rainfall uncertainty and control time steps on total overflow reduction rate

4 结 论

针对城市排水系统调控在模拟精度与控制效率上的双重挑战，本文以岳阳市洛王路排水片区为例，提出了基于图神经网络代理模型和强化学习的城市排水系统实时控制方法，并在多种降雨情景下进行了系统评价。主要结论如下：

- (1)图神经网络代理模型能够有效刻画排水系统的空间结构与时序特征，实现了高精度的流量与溢流过程模拟，测试期纳什效率系数达 0.969，为复杂调控策略的快速优化提供了可靠基础。
- (2)强化学习结合代理模型实现了以溢流最小化为目标的动态优化，相比遗传算法，不仅优化效果更好，最大削减率提升至 18.1%，且优化耗时显著降低，极大提升了工程应用的实时性。
- (3)在不同降雨强度、控制间隔与降雨不确定条件下，强化学习均表现出更高的溢流削减率与更强的稳健性，尤其在强降雨及高不确定性情景中仍保持优势，适用性更佳。

参考文献：

[1] 陈秋伶, 林凯荣, 陈文龙, 等. 多尺度海绵城市系统雨洪控制研究[J]. 水利学报, 2022, 53(7): 862-875. (CHEN Q L, LIN K R, CHEN W L, et al. Study on storm flood control in multi-scale sponge city system[J]. Journal of Hydraulic Engineering, 2022, 53(7): 862-875. (in Chinese))

[2] 李小宁, 郑世威, 李宥霖, 等. 基于地表-管道-河道耦合模拟的城市内涝风险评估[J]. 水科学进展, 2024, 35(5): 738-751. (LI X N, ZHENG S W, LI Y L, et al. Urban flood risk assessment based on integrated simulation of surface-pipe-river[J]. Advances in Water Science, 2024, 35(5): 738-751. (in Chinese))

[3] FAN J, LIU B Y, LEI T J, et al. Exploring how economic level drives urban flood risk[J]. *Nature Communications*, 2025, 16: 4857.

[4] KUMAR A S, MAJUMDER R, KAPADIA V P, et al. Partial flood defenses shift risks and amplify inequality in a core-periphery city[J]. *Nature Cities*, 2025, 2(9): 835-846.

- [5] 罗鑫燃, 郑雅莲, 刘攀, 等. 耦合不确定性的城市排水系统实时控制研究进展[J]. 水科学进展, 2025, 36(1): 109-121. (LUO X R, ZHENG Y L, LIU P, et al. Research progress on real-time control of urban drainage systems considering uncertainty[J]. *Advances in Water Science*, 2025, 36(1): 109-121. (in Chinese))
- [6] JEAN M, MORIN C, DUCHESNE S, et al. Real-time model predictive and rule-based control with green infrastructures to reduce combined sewer overflows[J]. *Water Research*, 2022, 221: 118753.
- [7] SUN L X, XIA J, SHE D X, et al. A predictive fuzzy logic and rule-based control approach for practical real-time operation of urban stormwater storage system[J]. *Water Research*, 2024, 266: 122437.
- [8] 罗鑫燃, 彭寿海, 王殿常, 等. 城市排水系统分布式控制研究进展与展望[J]. 水科学进展, 2025, 36(2): 345-357. (LUO X R, PENG S H, WANG D C, et al. Research advances and prospects for distributed control of urban drainage systems[J]. *Advances in Water Science*, 2025, 36(2): 345-357. (in Chinese))
- [9] 买伊伊, 刘攀, 罗鑫燃, 等. 基于 SWMM 的城市闸泵群防洪排涝滚动优化控制研究[J]. 中国农村水利水电, 2023(4): 208-214, 220. (MAI Y Y, LIU P, LUO X R, et al. Optimal rolling control of urban sluice pump group to decrease flood risk of a drainage system based on SWMM[J]. *China Rural Water and Hydropower*, 2023(4): 208-214, 220. (in Chinese))
- [10] TIAN W C, LIAO Z L, ZHI G Z, et al. Combined sewer overflow and flooding mitigation through a reliable real-time control based on multi-reinforcement learning and model predictive control[J]. *Water Resources Research*, 2022, 58(7): e2021WR030703.
- [11] LUO X R, LIU P, XIA Q, et al. Machine learning-based surrogate model assisting stochastic model predictive control of urban drainage systems[J]. *Journal of Environmental Management*, 2023, 346: 118974.
- [12] 侯精明, 张兆安, 马利平, 等. 基于 GPU 加速技术的非结构流域雨洪数值模型[J]. 水科学进展, 2021, 32(4): 567-576. (HOU J M, ZHANG Z A, MA L P, et al. Unstructured numerical model for rainfall-runoff process in watershed based on GPU acceleration technology[J]. *Advances in Water Science*, 2021, 32(4): 567-576. (in Chinese))
- [13] 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.
- [14] LU W, XIA W, SHOEMAKER C A. Surrogate global optimization for identifying cost-effective green infrastructure for urban flood control with a computationally expensive inundation model[J]. *Water Resources Research*, 2022, 58(4): e2021WR030928.
- [15] MEYER D, GRIMMOND S, DUEBEN P, et al. Machine learning emulation of urban land surface processes[J]. *Journal of Advances in Modeling Earth Systems*, 2022, 14(3): e2021MS002744.
- [16] DONNELLY J, DANESHKHAH A, ABOLFATHI S. Physics-informed neural networks as surrogate models of hydrodynamic simulators[J]. *Science of the Total Environment*, 2024, 912: 168814.
- [17] SUN A Y, JIANG P S, YANG Z L, et al. A graph neural network (GNN) approach to basin-scale river network learning: the role of physics-based connectivity and data fusion[J]. *Hydrology and Earth System Sciences*, 2022, 26(19): 5163-5184.
- [18] BAI T, TAHMASEBI P. Graph neural network for groundwater level forecasting[J]. *Journal of Hydrology*, 2023, 616: 128792.
- [19] LUO X R, LIU P, CHENG L, et al. Optimization of in-pipe storage capacity use in urban drainage systems with improved DP considering the time lag of flow routing[J]. *Water Research*, 2022, 227: 119350.
- [20] SIMONE A, CESARO A, del GIUDICE G, et al. Potentialities of complex network theory tools for urban drainage networks analysis[J]. *Water Resources Research*, 2022, 58(8): e2022WR032277.
- [21] AL-SHEHARI T, KADRIE M, AL-MHIQANI M N, et al. Comparative evaluation of data imbalance addressing techniques for CNN-based insider threat detection[J]. *Scientific Reports*, 2024, 14: 24715.
- [22] XIANG Z R, YAN J, DEMIR I. A rainfall-runoff model with LSTM-based sequence-to-sequence learning[J]. *Water Resources Research*, 2020, 56(1): e2019WR025326.
- [23] REISER P, NEUBERT M, EBERHARD A, et al. Graph neural networks for materials science and chemistry[J]. *Communications Materials*, 2022, 3: 93.
- [24] 宋晓猛, 徐楠涛, 张建云, 等. 中国城市洪涝问题: 现状、成因与挑战[J]. 水科学进展, 2024, 35(3): 357-373. (SONG X M, XU N T, ZHANG J Y, et al. Urban flooding in China: current status, causes and challenges[J]. *Advances in Water Science*, 2024, 35(3): 357-373. (in Chinese))
- [25] 丁诚, 王兆才, 丁伟杰, 等. 基于可解释多源数据特征融合的深度学习集合径流预测[J]. 水科学进展, 2025, 36(4): 581-595. (DING C, WANG Z C, DING W J, et al. Deep learning ensemble streamflow prediction based on explainable multi-source data

- feature fusion[J]. *Advances in Water Science*, 2025, 36(4): 581-595. (in Chinese))
- [26] YE H, LIU P, ZHANG X J, et al. Regarding reservoirs as switches: deriving restored and regulated runoff with one long short-term memory model[J]. *Journal of Hydrology: Regional Studies*, 2024, 56: 102062.
- [27] ZHANG A N, LIU P, CHENG Q, et al. Deriving reservoir operating rules of spillway gates based on deep reinforcement learning[J]. *Journal of Hydrology*, 2025, 662: 133858.
- [28] YIN L F, XIONG Y. Fast-apply deep autoregressive recurrent proximal policy optimization for controlling hot water systems[J]. *Applied Energy*, 2024, 367: 123348.
- [29] ZHOU C T, LIU P, LUO X R, et al. Uncertainty analysis method for diagnosing multi-point defects in urban drainage systems[J]. *Water Research*, 2025, 270: 122849.

Intelligent regulation of urban drainage systems based on graph neural network surrogate models*

ZHOU Chutian¹, LIU Pan¹, XU Qin^{2,3}, XIE Kang^{2,4}, CAI Jing^{2,5}

(1. *State Key Laboratory of Water Resources Engineering and Management, Wuhan University, Wuhan 430072, China*; 2. *The National Key Laboratory of Water Disaster Prevention, Nanjing Hydraulic Research Institute, Nanjing 210029, China*; 3. *Yangtze Institute for Conservation and Development, Nanjing 210098, China*; 4. *Research Center for Climate Change of Ministry of Water Resources, Nanjing 210029, China*; 5. *Wanjiang University of Technology, Ma'anshan 243031, China*)

Abstract: To address the challenge of balancing accurate simulation with efficient control in the real-time control of urban drainage systems, this study proposed an intelligent real-time control framework integrating a graph neural network (GNN) surrogate model with reinforcement learning (RL), aiming to enhance the effectiveness of overflow risk management. First, a GNN-based surrogate model, capable of efficiently simulating overflow in complex systems, was developed. Then, the surrogate model served as a virtual environment in which RL was used to achieve dynamic regulation of multiple actuator gates, with the objective of minimizing overflow. Using a drainage district in Yueyang City, China as a case study, the surrogate model achieved a Nash-Sutcliffe efficiency coefficient of 0.969 during the testing period, indicating high simulation accuracy. Under heavy rainfall conditions, the RL strategy based on the surrogate model reduced overflow volumes by up to 18.1%, with a single-step decision time of only 0.19 seconds. This was substantially faster than conventional methods, such as genetic algorithms, that required 16.2 minutes per step. Moreover, RL exhibited greater robustness under uncertainty scenarios. This study provides technical support for intelligent regulation of urban drainage systems.

Key words: urban drainage system; graph neural network; surrogate model; urban overflow; real-time control; intelligent regulation

* The study is financially supported by the National Natural Science Foundation of China (No. 52209031; No. U2443202).