

基于强化学习的城市河网实时控制优化方法

池商涛¹, 廖卫红², 高 尚³, 梁永帅⁴, 王 浩², 时维海²

(1. 福州大学土木工程学院; 2. 中国水利水电科学研究院水资源研究所; 3. 福州市城区水系联排联调中心;
4. 济南大学水利与环境学院)

摘要:为提升复杂城市河网的洪水风险调控水平,提出了基于强化学习的实时控制优化方法,并比较了单智能体强化学习(SARL)与多智能体强化学习(MARL)控制策略在排水调度中的性能差异。以福州市南台岛中部河网闸泵系统为例,采用 A3C 算法,结合机理模型对强化学习控制策略进行训练与验证,从平均最高水位、能耗与响应时效等方面开展系统评估。结果表明:在典型台风暴雨情景下,MARL 控制策略实现洪峰削减 13.8%、超警时长缩短 15 min、洪峰延迟 11 min,控制效果最优;SARL 控制策略效果虽略逊于 MARL 控制策略,但仍显著优于静态规则;MARL 控制策略单轮耗时 0.5 s,SARL 控制策略耗时 0.3 s,均满足实时控制需求;基于 A3C 算法的 MARL 控制策略兼顾调控性能与运行经济性,具有较强的协同能力与工程应用潜力。

关键词:洪水实时控制;泵闸协同调度;强化学习;InfoWorks ICM;福州市南台岛

Real-time control optimization method for urban river networks based on reinforcement learning//Chi Shangtao¹, Liao Weihong², Gao Shang³, Liang Yongshuai⁴, Wang Hao², Shi Weihai² (1. College of Civil Engineering, Fuzhou University; 2. Department of Water Resources, China Institute of Water Resources and Hydropower Research; 3. Fuzhou Urban Hydrographic Net Joint Drainage and Dispatch Center; 4. School of Water Conservancy and Environment, University of Jinan)

Abstract: To improve flood risk regulation in complex urban river networks, a real-time control optimization method based on reinforcement learning was proposed, and the control performance of single-agent reinforcement learning (SARL) and multi-agent reinforcement learning (MARL) strategies for drainage scheduling was compared. Taking the sluice-pump system of the central river network of Nantai Island in Fuzhou City as a case study, the asynchronous advantage actor-critic (A3C) algorithm was employed to train and validate the reinforcement learning-based control strategies using a hydrodynamic model. The control performance was systematically evaluated in terms of the average maximum water level, energy consumption, and response efficiency. The results show that, under a typical typhoon-induced rainstorm scenario, the MARL control strategy achieved the best performance, reducing the peak water level by 13.8%, shortening the duration above the warning water level by 15 min, and delaying the flood peak by 11 min. Although the SARL control strategy performed slightly worse than the MARL strategy, it still significantly outperformed the conventional static rule-based strategy. The average computation time for a single control step was 0.5 s for MARL and 0.3 s for SARL, indicating that both strategies satisfy the requirements of real-time control. Overall, the A3C-based MARL control strategy provides a favorable balance between flood regulation performance and operational economy, demonstrating strong coordination capability and considerable potential for engineering applications.

Key words: real-time flood control; coordinated gate-pump operation; reinforcement learning; InfoWorks ICM; Nantai Island of Fuzhou City

受气候变化和快速城市化的影响,城市洪水灾害日益严重,已成为城市安全和可持续发展的重大威胁^[1-3]。极端暴雨事件频发,城市不透水面积增加,导致(河网、湖泊等)调蓄空间不断萎缩,进一步加剧了城市洪水风险^[4-7]。河网作为城市排水系统

的重要组成部分,在行洪排涝和水资源调蓄中发挥着关键作用^[8]。强降雨下河网水位迅速上升,顶托排水管网无法及时排出雨水,导致管网溢流,引发洪涝灾害^[9-12],尤其是沿海城市,面临着更为严峻的洪涝挑战。在暴雨和潮汐的联合影响下,河网高水位

基金项目:新疆维吾尔自治区重大科技专项(2024A03011-2)

作者简介:池商涛(2001—),男,硕士研究生,主要从事城市洪涝预报研究。E-mail:ichuan258@163.com

通信作者:廖卫红(1986—),女,正高级工程师,博士,主要从事城市洪涝预报与分布式水文模拟研究。E-mail:liaowh@iwhr.com

持续顶托排水管网,高潮位阻碍排水,甚至引发潮水倒灌。因此,许多城市开展了河湖水系连通工作,建设了闸、泵等水工程以提升河网运行效率^[13-14]。面对城市洪水灾害,可通过洪水错峰调度与洪峰削减来降低河网对排水管网的顶托压力,减少系统溢流,提升城市抗洪能力,但这往往要求高效、准确的河网实时控制^[15-17]。因此,开展河网实时控制优化方法研究,对城市暴雨洪水管理具有重要现实意义。

河网实时控制是通过对水工程的实时调度来实现,包括基于规则的控制和基于序列的控制两种方法^[18]。基于规则的水工程控制在应对突发性暴雨事件时响应迟缓,对全区的调控效果有限。基于序列的控制是系统模型依据水位、潮位、降水量等时间序列数据进行动态优化决策,对于结构较简单的河网系统,往往只需生成较少的水工程控制序列即可实现有效调度。但对于具有复杂河网的城市,存在水工程控制的时空高维问题,基于序列的控制方法难以同时兼顾计算效率与控制精度,制约了其在复杂场景下的应用^[19-20]。当前城市河网普遍采用基于经验或规则的闸泵启闭调度方式,但在受潮汐顶托影响的复杂河网中,水位响应高度非线性、边界条件动态变化等因素,导致静态调控规则往往存在反应滞后和能耗偏高等问题。

强化学习作为机器学习的重要分支,是一种基于奖励反馈机制的序贯决策方法,已初步应用于自动驾驶、水库群联合优化运行等领域^[21-23]。近年来,国内外学者开始将强化学习引入城市河网的实时控制中。Mulapudi 等^[24]采用深度 Q 网络算法为城市雨水系统设计了实时控制策略,结果表明该策略在高强度降雨情景下显著优于无控制策略,但在面对多盆地复杂系统时存在收敛困难和计算资源需求过大的问题;Tian 等^[25]提出了融合强化学习与模型预测控制的混合控制框架,以降低强化学习输出的不稳定性;Saliba 等^[26]采用深度确定性策略梯度算法,研究了不确定性输入数据对强化学习算法在洪涝控制中的影响,结果表明强化学习算法能够保证一定的鲁棒性,但在面对复杂雨水管网阀门控制时存在频繁启闭的问题。

尽管已有研究表明强化学习在城市水系统控制中具有良好表现,但在面对复杂排水系统时仍存在控制策略不稳定、计算资源需求高等问题,且当前多聚焦于多智能体强化学习(multi-agent reinforcement learning, MARL)控制框架的设计与性能提升,尚缺乏针对单智能体强化学习(single-agent reinforcement learning, SARL)与 MARL 控制框架的系统性对比研究。SARL 控制框架仅需单一智能体完成决策,建

模相对简单,适用于规模较小的控制问题;而 MARL 控制框架结构具备更强的系统表达能力和空间分布性优势,但训练难度与协同复杂性显著增加^[27-28]。

本文基于强化学习提出一种面向城市河网工程系统的实时控制优化方法,分别构建 SARL 与 MARL 控制框架,对比二者对洪水风险控制的效果。选用 A3C(asynchronous advantage actor-critic)算法作为学习核心,直接处理河网系统中闸泵启闭等离散动作的决策问题^[29-30],以实现排水系统的科学高效运行,减少河网水位超警风险,降低河网对排水管网的顶托效应,缓解城市洪水灾害,为强化学习方法的工程化应用提供参考。

1 研究方法

1.1 Infoworks ICM

InfoWorks ICM 是由英国 Wallingford 公司开发的一款高度集成的水文水动力建模软件,在独立计算引擎内结合城市排水管网、河道水力系统与二维地表,将城市及流域水文模块、水动力模块、水质模块等进行耦合^[31]。InfoWorks ICM 基于子汇水区空间划分和不同下垫面的产流特性进行径流计算,汇流模型采用非线性水库法构建,管渠及河道水力计算采取圣维南方程组作为非恒定流控制方程。本文基于 InfoWorks ICM 构建研究区机理模型,并利用 ICM Exchange 接口实现强化学习方法与机理模型之间的实时数据交互,作为强化学习策略训练和控制效果验证的机理环境。

1.2 强化学习

强化学习是一种基于智能体与环境交互、以奖励反馈为驱动的机器学习方法。智能体通过不断采取不同控制动作与环境进行交互,根据环境反馈的奖励信号持续优化控制策略,以实现长期累积奖励最大化^[32-33]。针对城市河网实时控制问题,本文将河网运行过程抽象为强化学习决策过程,根据当前河网运行状态计算控制结果;智能体依据河网水位、降雨、潮位等状态信息进行闸泵调度,并根据控制效果获得奖励反馈,不断更新控制策略,实现河网实时优化调度。强化学习状态空间、动作空间及奖励函数结合应用实例构建。

1.3 A3C 算法

A3C 是一种基于策略梯度的深度强化学习算法^[34]。A3C 算法采用多线程异步更新机制,能够并行完成多个智能体与水动力模拟环境的交互,提高样本采集效率,缩短训练时间,适用于计算耗时较长的城市排水系统调度问题。Actor 策略网络根据边界条件(如关键节点水位、降水量等)输出排水系统

的控制动作, Critic 价值网络对当前状态下的策略进行价值评估, 并指导策略网络更新。为增强策略的探索能力, 在训练过程中引入熵正则项, 鼓励智能体在训练初期进行充分探索, 避免策略过早收敛, 从而提高控制策略的稳定性和适应性。

2 强化学习控制框架构建

以福州市南台岛中部河网为研究对象, 在建立研究区水文水动力模型的基础上, 构建 SARL 与 MARL 控制框架, 进行状态空间、动作空间和奖励函数设计, 并采用 A3C 算法进行控制策略训练。

2.1 研究区概况与数据来源

福州市地处福建省中部东端、闽江下游沿海地区, 年平均降水量 900~2 100 mm。近年来, 福州市多次遭受台风影响, 发生严重洪水灾害^[35]。2015 年 8 月“苏迪罗”台风、2023 年“杜苏芮”和“海葵”台风期间, 福州市遭受了极端暴雨事件, 加之风暴潮影响导致闽江异常涨潮, 河网水位迅速上涨, 潮水顶托河网排水, 造成城区不同程度的洪水灾害。本文选取福州市南台岛中部 39. 17 km² 的范围为研究区域(图 1), 地理位置为 25° 59′ N~26° 03′ N、119° 16′ E~119° 21′ E, 研究区水系相对独立, 地形以平原和丘陵为主, 沿江地区地势低洼^[36], 特别的地形和四面环江的条件, 使南台岛在遭受台风及风暴潮时更易产生洪水灾害。




图 1 研究区概况

Fig. 1 Overview of study area

采用的建模数据由福州市勘测院提供, 包括排水管网数据、河网数据、闸泵设计参数及运行规则、土地利用类型、DEM 数据、实测水位数据和实测降雨数据。选择研究区的仓山镇站、农科院站、高盖山

站 3 个雨量站的实测降雨数据作为模型输入, 基于雨量站地理坐标, 采用泰森多边形法对其控制区域进行空间划分。基于降雨事件划分样本集, 收集了 2020—2025 年共 67 场实测降雨事件, 涵盖台风强降雨和短历时强降雨, 降雨历时为 2~42 h, 降水量为 30~427 mm。为提升训练样本容量, 扩展降雨情景空间, 根据福州市暴雨强度公式^[37], 设计得到 60 场历时为 3~24 h 的设计降雨数据集, 降水量为 30~120 mm。选取 36 场实测降雨事件构成独立测试集, 用于总体性能评价; 其余实测降雨事件和 60 场设计降雨共 91 场降雨事件作为训练集, 用于强化学习控制策略训练。

2.2 水文水动力模型构建

优化后的雨水井、河道断面、排水口共 6 202 个, 排水管段、河段共 6 264 条。首先基于实际情况根据主干道、河网数据和 DEM 将研究区划分成一级子汇水区; 再在各一级子汇水区内根据雨水井的分布位置和河网数据, 采用泰森多边形法划分二级子汇水区; 最后结合研究区的地形资料、下垫面类型, 通过手动方式对二级子汇水区进行调整, 共得到 5 103 个子汇水区, 进而耦合二维地表, 构建模型计算网络。

采用 2022 年 3 月 26 日 14 时至 27 日 4 时的降雨事件(降水量为 68. 3 mm)校准模型, 校准参数包括不透水表面粗糙系数、透水表面粗糙系数、径流系数、河道曼宁系数等。采用 2024 年 7 月 24 日 16 时至 27 日 19 时的“格美”台风强降雨事件(降水量为 387. 5 mm)验证模型。从研究区中选取 4 个典型排口和 4 个河道断面作为校准与验证样本, 样本选择遵循的原则为: 样本覆盖研究区主要干流及潮汐影响显著河段, 监测数据连续性较好且满足数据质量要求, 从而保证率定结果能够反映河网系统的关键水力响应特征。评价结果如表 1 所示, 模拟水位的平均纳什效率系数 0. 86。根据 GB/T 22482—2008《水文情报预报规范》相关标准, 所选择的样本精度合格, 可支撑后续洪水调度策略训练与评估。

表 1 模型校准及验证评价结果

Table 1 Model calibration and validation evaluation

降雨场次	考核断面	峰值时间 误差/min	峰值水位 误差/m	模拟水位纳 什效率系数
校准降雨 事件	河道断面 1	25	0. 11	0. 87
	河道断面 2	5	0. 05	0. 93
	排口 1	15	0. 05	0. 89
	排口 2	5	0. 02	0. 95
验证降雨 事件	河道断面 3	55	0. 12	0. 68
	河道断面 4	10	0. 24	0. 74
	排口 3	25	0. 08	0. 87
	排口 4	15	0. 12	0. 93

2.3 基于 A3C 的实时控制框架构建

研究区共有 9 个闸站和 4 个泵站,共计 13 个闸泵控制节点,其中东岭闸站和浦下闸站长期处于封闭状态,不参与调度,故实际参与控制的闸泵节点为 11 个。为系统评估强化学习在复杂河网调度中的控制效果,分别构建了 SARL 与 MARL 两种控制框架。

在 SARL 控制框架下,将研究区内所有可控闸站与泵站视为一个统一控制系统,由单一智能体同时输出所有闸泵节点的联合调度决策,其动作空间由各闸站与泵站运行状态的笛卡尔积构成,用以刻画集中式调度在全局信息条件下的控制能力。

在 MARL 控制框架下,分别对研究区内每一个闸站和泵站构建独立智能体,各智能体仅负责对应泵站或闸站的运行决策,以反映分布式控制场景下的局部自主调度特征。研究区闸站水闸孔数为 1~3 孔,动作的空间维度定义为闸站开启的水闸孔数,对应单个闸站智能体动作的空间维度为 2~4;各泵站水泵数量为 2~4 台,动作的空间维度定义为投入运行的水泵数量,对应单个泵站智能体动作的空间维度为 3~5。综上,在 MARL 控制框架下,共构建 11 个智能体,其动作空间维度取值范围为 2~5。MARL 采用集中训练、分散执行机制。训练阶段,各闸泵智能体在统一的 ICM 环境中并行交互,采用参数共享的 A3C 算法进行异步更新,并基于全局累计回报不断优化协同调度策略;执行阶段,各智能体仅依据自身观测到的局部状态独立输出控制动作,无需获取其他智能体的实时信息。

智能体状态向量包括各闸泵控制范围内 3 个关键河道断面的水位 $H_i(i=1,2,3)$ 、第 $j(j=1,2,3)$ 个雨量站 t 时刻降水量观测值 $P_{j,t}$ 和 $t+1$ 时刻降水量预报值 $P_{j,t+1}$ 、控制单元外江潮位 z_t 和 z_{t+1} 和 $t-1$ 时刻闸泵的状态 α_{t-1} ,状态向量能够全面刻画系统运行状况。为表征水力响应滞后效应,进一步在关键河道断面水位变量中引入有限阶滞后信息,拼接 $t-1$ 和 $t-2$ 时刻关键河道断面水位构成扩展状态,以提升控制策略对系统惯性的感知能力。

为确保控制策略的稳定性与效率,综合多组试验调试结果与表现,最终将参数设定为:强化学习与 ICM 仿真采用统一控制时间步长,为 5 min;网络采用两层全连接结构,隐藏层神经元数为 128 与 64,激活函数为 ReLU;折扣因子、熵系数、学习率分别为 0.95、0.01 和 0.0007;最大训练迭代次数为 3000。每代训练中,智能体从训练集中随机选取 4 个降雨过程作为一个批次,完成状态-动作-奖励轨迹的采样与策略优化,整体过程如图 2 所示(图中 m 、 n 分别为当前批次环境交互的时间步数和网络参数更新

的训练迭代次数)。




图 2 强化学习训练流程

Fig. 2 Training flowchart for reinforcement learning

选取安全指标和经济指标作为排水系统实时控制目标,引导智能体学习,从而得到既可降低洪水风险又可兼顾运行成本的调控策略。通过两类指标加权求和计算即时奖励:

$$R_t = w_s R_{s,t} + w_e R_{e,t} \tag{1}$$

式中: R_t 为智能体在 t 时刻获得的即时奖励; $R_{s,t}$ 、 $R_{e,t}$ 分别为系统在 t 时刻的安全指标和经济指标; w_s 、 w_e 分别为安全指标和经济指标权重,且 $w_s + w_e = 1$ 。考虑到本文研究城市洪水治理的首要目标是降低河网超警风险和排口顶托风险,通过对不同权重组合下控制效果与训练稳定性的对比分析,最终确定 $w_s = 0.7$ 、 $w_e = 0.3$ 。

安全指标 $R_{s,t}$ 的总体控制目标是将流域内排水系统水位保持在超警水位以下,并尽可能将排口顶托风险降至最低。 $R_{s,t}$ 的计算公式为:

$$R_{s,t} = R_{se,t} + R_{ou,t} \tag{2}$$

其中 $R_{se,t} = \begin{cases} \sum_{i=1}^{n_a} -w_{a,i}(h_{se,i,t} - H_{w,i}) & h_{se,i,t} \geq H_{w,i} \\ 1 & h_{se,i,t} < H_{w,i} \end{cases}$

$$R_{ou,t} = - \sum_{j=1}^{n_b} w_{b,j} \max(h_{ou,j,t} - H_{ou,j}, 0)$$

式中: $R_{se,t}$ 为 t 时刻河道断面超警风险指标,用于表征河网运行安全性,当断面水位超过警戒水位时,根据超警程度对智能体施加相应惩罚,从而引导智能体优先降低河网超警风险; $R_{ou,t}$ 为 t 时刻管网排口的漫溢风险指标,当内河水位升高导致排口排水受阻时,对智能体施加相应惩罚,从而引导调度策略降低排口顶托风险; $w_{a,i}$ 为第 i 个河道断面的权重; $h_{se,i,t}$ 为 t 时刻第 i 个河道断面的水位; $H_{w,i}$ 为第 i 个河道断面的超警水位; $w_{b,j}$ 为管网第 j 个排口的权

重; $h_{ou,j,t}$ 为 t 时刻第 j 个排口水位; $H_{ou,j}$ 为第 j 个排口的允许运行水位; n_a 、 n_b 分别为河道断面和排口数量。

经济指标 $R_{e,t}$ 包含能耗惩罚项和启闭频繁性惩罚项 2 个子项(式(3))。首先依据泵站理论功耗计算水泵运行能耗,并将其作为能耗惩罚项纳入奖励函数,以约束高能耗运行工况。为避免泵闸设备频繁启闭造成机械损耗,设计了启闭频繁性惩罚项。当前时刻控制动作与上一时刻不一致时,判定为一次启闭切换,并施加相应惩罚,以减少设备频繁启闭。

$$R_{e,t} = - \left(w_1 \sum_{k=1}^{N_p} P_{k,t} + w_2 \sum_{k=1}^{N_p} \delta_{p,k,t} + w_3 \sum_{l=1}^{N_s} \delta_{g,l,t} \right) \quad (3)$$

其中

$$P_{k,t} = r_k Q_{k,t} H_{k,t}$$

$$\delta_{p,k,t} = |\alpha_{p,k,t} - \alpha_{p,k,t-1}|$$

$$\delta_{g,l,t} = |\alpha_{g,l,t} - \alpha_{g,l,t-1}|$$

式中: $P_{k,t}$ 为 t 时刻第 k 台泵的能耗惩罚值,由泵运行功率估算得到; r_k 为第 k 台泵单位能耗系数; $Q_{k,t}$ 、 $H_{k,t}$ 分别为 t 时刻第 k 台泵的瞬时流量和扬程; $\delta_{p,k,t}$ 、 $\delta_{g,l,t}$ 分别为第 k 台泵和第 l 个水闸的运行状态切换次数; $\alpha_{p,k,t}$ 、 $\alpha_{g,l,t}$ 分别为泵和水闸的运行状态,且 $\alpha_{p,k,t} \in \{0,1\}$, $\alpha_{g,l,t} \in \{0,1\}$; N_p 、 N_s 分别为泵和水闸的数量; w_1 、 w_2 、 w_3 为对应项的权重。

为避免控制策略输出的调度动作偏离实际运行约束,引入生态水位和闸泵启闭操作时间间隔约束条件。

- a. 生态水位约束:
- $$h_{se,i,t} \geq H_{e,i} \quad (4)$$
- 式中: $H_{e,i}$ 为第 i 个河道断面的生态水位。
- b. 闸泵启闭操作时间间隔不低于最短操作时间间隔,即:

$$t_{o,l} - t_{c,l} \geq \Delta t_{\min} \quad (5)$$

$$t_{o,k} - t_{c,k} \geq \Delta t_{\min} \quad (6)$$

式中: $t_{o,l}$ 、 $t_{c,l}$ 分别为第 l 个水闸开启和关闭时间; $t_{o,k}$ 、 $t_{c,k}$ 分别为第 k 台泵开启和关闭时间; $\Delta t_{\min}$ 为闸泵启闭最短操作时间间隔,本文取 $\Delta t_{\min} = 10 \text{ min}$ 。

上述约束在策略执行层以硬约束方式实现。当调度动作不满足约束条件时,采用动作可行域筛选,将该动作从可选集合中剔除,并在可行动作集中重新采样/选择,从而保证输出控制序列满足工程运行约束。

3 结果与分析

3.1 控制策略训练过程分析

3.1.1 训练效率

图 3(a) 为 MARL 控制策略下各智能体平均奖励值随训练代数的变化趋势。各智能体平均奖励值

整体表现出稳定上升并逐步收敛的特征,在第 1 100 代左右奖励值趋于稳定且波动幅度显著减小,表明控制策略已由初始探索阶段转入收敛优化阶段,智能体控制能力逐步增强。SARL 控制策略在训练过程中表现出更强的震荡性与不稳定性(图 3(b)),奖励值曲线波动较大,整体上升速率较慢,约至第 2 100 代才逐渐收敛,显示其在复杂控制任务中存在显著的训练难度。主要原因在于,单智能体需要在更大的状态-动作空间中同时学习多个控制单元的协同策略,导致策略收敛过程缓慢、易陷入局部最优。为避免单次训练的偶然性影响结论,本文在不同随机种子下重复训练多次,统计平均奖励值与关键指标的均值与标准差。结果表明 MARL 控制策略收敛速度更快,且标准差更小,SARL 控制策略仍存在更明显的训练震荡。




图 3 不同控制策略奖励值变化过程
Fig. 3 Variation process of reward values under different control strategies

训练耗时方面,在相同计算资源下(CPU: Intel (R) Xeon (R) w5-2455X/24 核/3.19GHz;显卡: Nvidia Geforce RTX 3070),MARL 控制策略训练耗时约为 46h,而 SARL 控制策略因缺乏并行机制,学习任务更重,训练总耗时约为 71 h。可见在规模闸泵调度任务中,MARL 控制策略不仅具备更高的策略收敛能力,也具有更优的训练效率与工程可扩展性。

3.1.2 策略稳定性

为进一步验证 SARL 和 MARL 控制策略收敛情况与控制动作稳定性,本文选取 2022 年一场具有典

型结构的暴雨过程(降雨历时 6 h, 总降水量 80 mm), 并以片区内义序泵站为分析对象, 对比训练初期(第 100 代)与训练收敛后强化学习控制策略在该场次暴雨过程中的启闭控制序列。

如图 4 所示, 训练初期该泵站控制动作波动剧烈, 缺乏明确调控逻辑, 存在频繁启闭现象, 无法有效响应降雨过程; 在暴雨初期至主峰期控制状态切换频繁, 表现出较强的随机性, 控制策略尚未形成稳定操作模式。而训练收敛后, 泵站控制序列展现出明确的时间逻辑和稳定的操作特征。智能体能够在降雨前提前开启水泵, 在主雨期维持开启状态, 降雨末端及时关闭, 有效完成“预排-应对-退水”3 阶段调控任务。

此外, 亦参考其他闸站、泵站在该场降雨下的控制动作, 结果显示各智能体输出的控制策略普遍具有较强规律性, 进一步从空间维度印证了输出控制策略的一致性。

3.2 控制策略整体性能评估

以独立测试集的 36 场降雨事件为例, 对 MARL、SARL 与静态规则 3 种控制策略下的效果进行统计对比。综合考虑防洪安全与运行代价两类目标, 选取控制断面最高水位与闸泵能耗惩罚值作为主要评价指标。

如图 5(a) 所示, MARL、SARL 与静态规则 3 种

控制策略下各控制断面最高水位均值分别为 4.82、4.95、5.05 m。相较于静态规则, MARL 和 SARL 控制策略各控制断面最高水位均值分别削减 0.23、0.10 m, MARL 控制策略在大部分场次中表现出更低的平均水位, 具备更强的协同调度能力; SARL 策略虽控制能力略逊, 但在多数场次中亦优于静态规则。

如图 5(b) 所示, 相较于静态规则, MARL 和 SARL 控制策略能耗惩罚值分别提升 6.9% 和 15.7%, 这是由于强化学习控制策略倾向于提前开启水泵预留调蓄空间以缓解水位超警风险, 尽管因此能耗略有增加, 但显著提升了水位控制的主动性。考虑到极端强降雨条件下的超警漫溢风险, 以适度能耗换取更高安全裕度, 是一种合理且可接受的工程权衡。上述分析结果从整体上验证了强化学习控制策略在提升城市排水系统调控能力方面的潜力, 并凸显了 MARL 控制策略在协同优化与经济权衡方面的综合优势。

3.3 典型洪水事件响应效果分析

为验证强化学习控制策略在典型强降雨过程中的实际控制能力, 选取 2023 年 7 月“杜苏芮”台风影响下的实测降雨过程(图 6)作为测试场景, 对比静态规则、SARL 与 MARL 控制策略对河网的实时控制能力与效率。该场景下降雨历时为 36 h, 降水




图 4 义序泵站不同控制策略训练初期与收敛后的控制序列对比

Fig. 4 Comparison of control sequences at Yixu Pumping Station in initial training stage and convergence stage under different control strategies




图 5 3 种控制策略下的调度效果对比

Fig. 5 Comparison of scheduling performance under three control strategies

量为 366 mm。




图 6 “杜苏芮”台风降雨过程及外江潮位

Fig. 6 Rainfall process of Typhoon “Doksuri” and outer river tidal level

3.3.1 河道水位控制效果

如表 2 所示, MARL 控制策略在河道断面最高水位、超警时长和首次超警时长均值 3 个指标上均表现出最优性能。具体来看, MARL 控制策略将河道断面最高水位均值从静态规则的 5.483 m 降低至 5.261 m, 相较于洪水涨幅, 峰值削减约 13.8%; 超警时长均值由 273 min 缩短至 248 min, 首次超警时间均值延迟至 766 min。

表 2 不同控制策略下河网关键水位响应指标

Table 2 Key water level response indicators in river networks under different control strategies

控制策略	河道断面最高水位均值/m	超警时长均值/min	首次超警时间均值/min
静态规则	5.483	273	752
MARL	5.261	248	766
SARL	5.355	254	763

图 7 为 3 种控制策略下 4 个典型河道断面的水位过程。可以看出, 强化学习控制策略显著改善了系统的调蓄响应, 通过雨前预降水位, 强化学习控制策略洪峰高度普遍低于静态规则, 且洪峰时间整体延后 10~20 min。其中, MARL 控制策略下水位过程最为平稳, 表明其在面对暴雨洪水过程时具备更强的提前调控能力与系统协调性。

3.3.2 闸泵动作过程与能耗

为进一步分析 3 种控制策略的控制逻辑, 对阳岐泵站在不同控制策略下的启闭控制序列进行对比, 结果如图 8 所示。静态规则在降雨初期基本无动作, 仅在洪峰阶段集中开启全部水泵, 调度刚性, 响应滞后, 难以发挥河网调蓄功能; SARL 控制策略具备一定的预降水位能力, 但控制动作呈现明显的“全开-全关”高频震荡、水泵频繁切换状态, 存在策略不稳定性与运行冗余的问题; MARL 控制策略则展现出更为柔性化的调控逻辑, 能根据未来降雨趋势与局部水位变化, 灵活启用 1~4 台泵, 控制过程更平滑, 水位响应也更稳定。

为定量评估不同控制策略下泵闸站运行的经济




图 7 3 种控制策略下典型河道断面水位过程

Fig. 7 Hydraulic head process of typical river cross-sections under three control strategies




图 8 3 种控制策略下阳岐泵站的启闭过程控制序列

Fig. 8 Control sequences of opening and closing operation processes at Yangqi Pumping Station under three control strategies

性, 统计了典型暴雨过程中闸泵运行能耗指标与启闭次数, 结果见表 3。相较于静态规则, SARL 与 MARL 控制策略均提高了闸泵启闭频率与总能耗水平。典型洪水事件下, MARL 控制策略在能耗增加

32%的基础上,实现了一定的水位削峰与响应优化;SARL 控制策略因闸泵启闭控制震荡,导致能耗提升 26%,经济性相对较差。综合来看,MARL 控制策略在实现高效排水调控的同时,兼顾了启闭节奏的工程可行性,表现出良好的系统适用性与部署潜力。

表 3 不同控制策略下经济指标对比

Table 3 Comparison of economic indicators under different control strategies			
控制策略	能耗惩罚值	水泵启闭次数	水闸启闭次数
静态规则	541	17	25
MARL	714	34	29
SARL	679	47	42

3.3.3 控制响应计算效率

在相同硬件条件下,SARL 控制策略平均决策计算时间约为 0.3 s,具备较高的响应速度;MARL 控制策略由于需并行输出多个控制单元的动作,其单轮决策耗时略长,约为 0.5 s,但仍满足洪水控制对实时性的要求(以 10 min 控制步长为基准)。

4 结 论

a. 使用 ICM Infoworks 构建了福州市南台岛中部片区的水文水动力模型,经率定后结果表明,模型模拟水位的纳什效率系数为 0.86,所构建的水文水动力模型能够满足强化学习控制策略对环境交互模型的模拟精度要求。

b. 基于典型洪水过程对静态规则、SARL 和 MARL 3 种控制策略响应对比分析结果表明,SARL 控制策略虽具有一定的调度优化能力,但在应对高维、强耦合的河网系统时,难以全面感知多节点水位与流量的时空耦合关系,存在闸泵启闭频繁、过度控制等问题。而 MARL 控制策略通过智能体间的时空协同与分布式学习,在控制河道水位峰值、缩短超警时长和积水历时等方面表现更优,显著提升了排水系统的抗洪能力与调度效率。

c. 计算效率方面,在典型洪水事件响应阶段,SARL 控制策略的平均响应时间约为 0.3 s,MARL 控制策略的平均响应时间约为 0.5 s。SARL 具有计算简洁、决策速度快的优势,两种强化学习控制策略均能在 1 s 内给出最优控制指令,远小于实际调度系统的控制步长(10 min),具备满足实时控制需求的运行效率。

参考文献:

[1] 张金良,罗秋实,王冰洁,等. 城市极端暴雨洪涝灾害成因及对策研究进展[J]. 水资源保护,2024,40(1):6-15. (Zhang Jinliang, Luo Qiushi, Wang Bingjie, et al. Research progress on causes and countermeasures for

extreme rainstorm-induced urban flood disasters [J]. Water Resources Protection, 2024, 40 (1): 6-15. (in Chinese))

[2] 舒心怡,徐宗学,叶陈雷,等. 海绵措施空间布局优化下的晋城市洪涝水深-流速联合分布特征[J]. 水资源保护,2025,41(1):76-84. (Shu Xinyi, Xu Zongxue, Ye Chenlei,et al. Flood depth-flow velocity joint distribution characteristics of Jincheng City under spatial layout optimization of sponge facilities [J]. Water Resources Protection,2025,41(1):76-84. (in Chinese))

[3] 刘丁蓉,杨凯,孙仕. 珠三角城市群内涝灾害韧性综合评估及障碍因子识别[J]. 水利经济,2024,42(4):23-29. (Liu Dingrong, Yang Kai, Sun Shi. Comprehensive assessment and obstacle factor recognition of waterlogging disaster resilience in Pearl River Delta urban agglomeration [J]. Journal of Economics of Water Resources ,2024,42(4):23-29. (in Chinese))

[4] 张建云,宋晓猛,王国庆,等. 变化环境下城市水文学的发展与挑战:I. 城市水文效应[J]. 水科学进展,2014,25(4):594-605. (Zhang Jianyun, Song Xiaomeng, Wang Guoqing, et al. Development and challenges of urban hydrology in a changing environment: I. hydrological response to urbanization[J]. Advances in Water Science, 2014,25(4):594-605. (in Chinese))

[5] Wang Peng, Li Yabo, Zhang Yuhu. An urban system perspective on urban flood resilience using SEM:evidence from Nanjing City, China[J]. Natural Hazards, 2021, 109 (3):2575-2599.

[6] 徐宗学,卢兴超,施奇妙. 城市暴雨洪涝灾害特征与风险评估研究进展[J]. 水利水电科技进展, 2025, 45 (1):1-9. (Xu Zongxue, Lu Xingchao, Shi Qimiao. Research progress on urban flooding disaster characteristics and risk assessment [J]. Advances in Science and Technology of Water Resources, 2025, 45 (1):1-9. (in Chinese))

[7] Kalantari Z, Ferreira C S S, Page J, et al. Meeting sustainable development challenges in growing cities: coupled social-ecological systems modeling of land use and water changes[J]. Journal of Environmental Management, 2019,245:471-480.

[8] Zhang Wei, Villarini G, Vecchi G A, et al. Urbanization exacerbated the rainfall and flooding caused by hurricane Harvey in Houston [J]. Nature, 2018, 563 (7731): 384-388.

[9] 王兆礼,陈昱宏,赖成光. 基于 TELEMAC-2D 和 SWMM 模型的城市内涝数值模拟[J]. 水资源保护,2022,38(1):117-124. (Wang Zhaoli, Chen Yuhong, Lai Chengguang. Numerical simulation of urban waterlogging based on TELEMAC-2D and SWMM model [J]. Water Resources Protection, 2022, 38 (1): 117-124. (in Chinese))

- [10] 侯俊,陈诚,郑玉磊,等. 基于 MIKE FLOOD 模型的平原水网地区内涝治理效果模拟研究[J]. 水利水电科技进展, 2024, 44 (6): 41-47. (Hou Jun, Chen Cheng, ZhengYulei, et al. Simulation study on effectiveness of waterlogging control in plain water network areas based on MIKE FLOOD model [J]. Advances in Science and Technology of Water Resources, 2024, 44 (6): 41-47. (in Chinese))
- [11] 吕恒,倪广恒,田富强. 排水管网结构概化对城市暴雨洪水模拟的影响[J]. 水力发电学报, 2018, 37 (11): 97-106. (Lyu Heng, Ni Guangheng, Tian Fuqiang. Impacts of drainage pipe network complexity on urban stormwater modeling [J]. Journal of Hydroelectric Engineering, 2018, 37 (11): 97-106. (in Chinese))
- [12] 卢兴超, 徐宗学, 李永坤, 等. 基于 SWMM 与 LISFLOOD-FP 耦合模型的城市街区内涝模拟研究 [J]. 水资源保护, 2024, 40 (3): 98-105. (Lu Xingchao, Xu Zongxue, Li Yongkun, et al. Research on urban block waterlogging simulation based on coupling model of SWMM and LISFLOOD-FP [J]. Water Resources Protection, 2024, 40 (3): 98-105. (in Chinese))
- [13] Zhang Ling, Nan Zhuotong, Liang Xu, et al. Application of the MacCormack scheme to overland flow routing for high-spatial resolution distributed hydrological model [J]. Journal of Hydrology, 2018, 558: 421-431.
- [14] Tang Hongwu, Yuan Saiyu, Cao Hao. Theory and practice of hydrodynamic reconstruction in plain river networks [J]. Engineering, 2023, 24: 202-211.
- [15] Meneses E J, Gaussens M, Jakobsen C, et al. Coordinating rule-based and system-wide model predictive control strategies to reduce storage expansion of combined urban drainage systems: the case study of Lundtofte, Denmark [J]. Water, 2018, 10 (1): 76.
- [16] García L, Barreiro-Gomez J, Escobar E, et al. Modeling and real-time control of urban drainage systems: a review [J]. Advances in Water Resources, 2015, 85: 120-132.
- [17] Tian Wenchong, Liao Zhenliang, Zhang Zhiyu, et al. Flooding and overflow mitigation using deep reinforcement learning based on Koopman operator of urban drainage systems [J]. Water Resources Research, 2022, 58 (7): e2021WR030939.
- [18] 徐存东, 任子豪, 黄嵩, 等. 基于动态规划理论的 MIKE21 河网排水方案优化研究 [J]. 环境工程, 2023, 41 (1): 79-86. (Xu Cundong, Ren Zihao, Huang Song, et al. Optimization of MIKE21 river network drainage scheme based on dynamic planning theory [J]. Environmental Engineering, 2023, 41 (1): 79-86. (in Chinese))
- [19] Puig V, Ocampo-Martinez C, Negenborn R R. Model predictive control for combined water supply and navigability/sustainability in river systems [M] // Ocampo-Martinez C, Negenborn R R. Transport of Water versus Transport over Water: Exploring the Dynamic Interplay of Transport and Water. Cham: Springer, 2015: 13-33.
- [20] Chen Yang, Wang Chao, Yang Qiu, et al. Model predictive control and rainfall uncertainties: performance and risk analysis for drainage systems [J]. Journal of Hydrology, 2024, 630: 130779.
- [21] 何逸煦, 林泓熠, 刘洋, 等. 强化学习在自动驾驶技术中的应用与挑战 [J]. 同济大学学报 (自然科学版), 2024, 52 (4): 520-531. (He Yixu, Lin Hongyi, Liu Yang, et al. Applications and challenges of reinforcement learning in autonomous driving technology [J]. Journal of Tongji University (Natural Science), 2024, 52 (4): 520-531. (in Chinese))
- [22] 王一聪, 陈明洪. 权衡生态和发电目标的梯级水库强化学习模型及其应用 [J]. 水电能源科学, 2024, 42 (2): 188-191. (Wang Yicong, Chen Minghong. Reinforcement learning model and its application for balancing ecological and power generation objectives of cascaded reservoirs [J]. Water Resources and Power, 2024, 42 (2): 188-191. (in Chinese))
- [23] 徐弘玮, 徐刚, 吴碧琼, 等. 基于深度强化学习的三峡电站机组负荷分配实时决策方法 [J]. 水力发电学报, 2024, 43 (8): 76-88. (Xu Hongwei, Xu Gang, Wu Biqiong, et al. Real-time decision-making method for unit commitment of Three Gorges Hydropower Station based on deep reinforcement learning [J]. Journal of Hydroelectric Engineering, 2024, 43 (8): 76-88. (in Chinese))
- [24] Mullapudi A, Lewis M J, Gruden C L, et al. Deep reinforcement learning for the real time control of stormwater systems [J]. Advances in Water Resources, 2020, 140: 103600.
- [25] Tian Wenchong, Liao Zhenliang, Zhi Guozheng, 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.
- [26] Saliba S M, Bowes B D, Adams S, et al. Deep reinforcement learning with uncertain data for real-time stormwater system control and flood mitigation [J]. Water, 2020, 12 (11): 3222.
- [27] Lowe R, Wu Yi, Tamar A, et al. Multi-agent actor-critic for mixed cooperative-competitive environments [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc. , 2017: 6382-6393.
- [28] Busoniu L, Babuska R, De Schutter B. A comprehensive survey of multiagent reinforcement learning [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 2008, 38 (2): 156-172.
- [29] Chen Miaojiang, Wang Tian, Ota K, et al. Intelligent resource allocation management for vehicles network: an

A3C learning approach [J]. Computer Communications, 2020, 151: 485-494.

[30] Peng Xuebin, Abbeel P, Levine S, et al. DeepMimic: example-guided deep reinforcement learning of physics-based character skills [J]. ACM Transactions on Graphics, 2018, 37(4): 143.

[31] 邹家祥,段存存,陈彬,等. 气候变化下基于经济损失量化的北京市内涝韧性评估[J]. 水资源保护, 2024, 40(6): 85-94. (Zou Jiayang, Duan Cuncun, Chen Bin, et al. Assessment of waterlogging resilience in Beijing based on quantification of economic losses under climate change [J]. Water Resources Protection, 2024, 40(6): 85-94. (in Chinese))

[32] Sutton R S, Barto A G. Reinforcement learning: an introduction[M]. Cambridge: MIT Press, 1998.

[33] Arulkumaran K, Deisenroth M P, Brundage M, et al. A brief survey of deep reinforcement learning [J]. IEEE Signal Processing Magazine, 2017, 34(6): 26-38.

[34] Mnih V, Badia A P, Mirza M, et al. Asynchronous methods for deep reinforcement learning [C]//Proceedings of the 33rd International Conference on Machine Learning. New York: JMLR.org, 2016: 1928-1937.

[35] 叶陈雷,徐宗学,雷晓辉,等. 基于 SWMM 和 InfoWorks ICM 的城市街区洪涝模拟与分析[J]. 水资源保护, 2023, 39(2): 87-94. (Ye Chenlei, Xu Zongxue, Lei Xiaohui, et al. Flood simulation and risk analysis on urban block scale based on SWMM and InfoWorks ICM [J]. Water Resources Protection, 2023, 39(2): 87-94. (in Chinese))

[36] Lian J J, Xu K, Ma C. Joint impact of rainfall and tidal level on flood risk in a coastal city with a complex river network: a case study of Fuzhou City, China [J]. Hydrology and Earth System Sciences, 2013, 17(2): 679-689.

[37] 陈奕. 福州市暴雨强度公式优化研究[J]. 给水排水, 2013, 39(10): 36-40. (Chen Yi. Optimization of rainstorm intensity formula for Fuzhou City [J]. Water & Wastewater Engineering, 2013, 39(10): 36-40. (in Chinese))

(收稿日期: 2025-10-10 编辑: 施业)

+++++

(上接第 177 页)

[25] 高桂霞. 大系统分解协调在库群防洪优化调度中的应用[J]. 东北水利水电, 2007, 25(3): 42-44. (Gao Guixia. Application of large system decomposition coordination in flood control optimization operation of reservoir group [J]. Water Resources & Hydropower of Northeast China, 2007, 25(3): 42-44. (in Chinese))

[26] 董姗姗,齐雪. 辅助函数构造法证明微分中值定理及其应用[J]. 通化师范学院学报, 2019, 40(8): 22-25. (Dong Shanshan, Qi Xue. The method of auxiliary function construction in certifications and applications of differential mean value theorem [J]. Journal of Tonghua Normal University, 2019, 40(8): 22-25. (in Chinese))

[27] 高庆娴. 构造拉格朗日定理辅助函数的几种方法[J]. 吉林师范学院学报, 1996, 17(12): 42-43. (Gao Qingxian. Several methods for constructing auxiliary functions for Lagrange's theorem [J]. Journal of Jilin Teachers College, 1996, 17(12): 42-43. (in Chinese))

[28] 欧阳龙. 基于龙格库塔优化算法的三级串联泵站优化调度分析[J]. 水利科学与寒区工程, 2025, 8(7): 120-123. (Ouyang Long. Optimization scheduling analysis of three-stage series pumping stations based on the Runge-Kutta optimization algorithm [J]. Hydro Science and Cold Zone Engineering, 2025, 8(7): 120-123. (in Chinese))

[29] 李贞蓉,张雷克,刘小莲,等. 基于龙格库塔算法的梯级泵站优化运行[J]. 水电能源科学, 2024, 42(4): 164-167. (Li Zhenrong, Zhang Leike, Liu Xiaolian, et al. Optimal operation of cascade pumping station based on Runge-Kutta algorithm [J]. Water Resources and Power, 2024, 42(4): 164-167. (in Chinese))

[30] 王翌旭,刘强,钟平安,等. 低调节性能水库防洪优化调度分段试算法改进[J]. 南水北调与水利科技(中英文), 2021, 19(3): 598-605. (Wang Yixu, Liu Qiang, Zhong Pingan, et al. Improved stage-wise trial-and-error method for optimal flood control operation of reservoirs with a low regulation capacity [J]. South-to-North Water Transfers and Water Science & Technology, 2021, 19(3): 598-605. (in Chinese))

[31] 段唯鑫. 汉江流域控制性水库调度运行及影响研究[D]. 武汉: 武汉大学, 2017.

[32] 董付强,丁洪亮,穆青青,等. 以丹江口水库为核心的汉江上游水库群联合调度初步实践与探讨[J]. 中国防汛抗旱, 2019, 29(6): 9-12. (Dong Fuqiang, Ding Hongliang, Mu Qingqing, et al. Preliminary practice and discussion on joint-dispatching of upper reaches of Hanjiang River with Danjiangkou Reservoir as the core [J]. China Flood & Drought Management, 2019, 29(6): 9-12. (in Chinese))

[33] 胡维忠,王乐,刘佳明. 长江流域防洪工程体系能力提升建设思路[J]. 中国水利, 2022(5): 31-34. (Hu Weizhong, Wang Le, Liu Jiaming. Ideas of capacity building for flood control engineering system in the Yangtze River Basin [J]. China Water Resources, 2022(5): 31-34. (in Chinese))

(收稿日期: 2025-11-10 编辑: 施业)