

基于超分辨率重建方法的城市内涝快速精细模拟

陈文杰¹, 黄俊烽¹, 梅超², 黄国如³, 刘家宏²

(1. 华南农业大学水利与土木工程学院; 2. 中国水利水电科学研究院流域水循环与水安全全国重点实验室;
3. 华南理工大学土木与交通学院)

摘要:针对城市内涝模拟中物理机理模型效率与精度难以平衡的问题,提出了一种基于 U-Net 超分辨率重建的城市内涝快速精细模拟方法,通过以粗精度积水结果为物理先验,实现从粗精度到细精度积水分布的快速映射。以深圳市民治片区为研究区,构建粗、细两套水动力模拟网格,结合地形及其衍生特征作为多通道输入训练深度学习模型,并与一维-二维耦合水动力模型的模拟结果进行对比。结果表明:超分辨率重建方法在多数设计暴雨情景下能准确还原积水空间格局和峰值特征,纳什效率系数普遍超过 0.9,均方根误差低于 0.15,与一维-二维耦合水动力模型相比,对 2 h 暴雨过程模拟的效率提升了 50.71 倍;随着暴雨重现期增大,超分辨率重建方法对整体积水特征的重建更为稳定,但在局部低洼与管网复杂区域仍存在偏差。

关键词:城市内涝模拟;超分辨率重建方法;深度学习模型;水动力模型;深圳市

Rapid and precise simulation of urban waterlogging based on super-resolution reconstruction method//Chen Wenjie¹, Huang Junfeng¹, Mei Chao², Huang Guoru³, Liu Jiahong² (1. College of Water Conservancy and Civil Engineering, South China Agricultural University; 2. State Key Laboratory of Water Cycle and Water Security, China Institute of Water Resources and Hydropower Research; 3. School of Civil Engineering & Transportation, South China University of Technology)

Abstract: In response to the difficulty of balancing the efficiency and accuracy of physical mechanism models in urban waterlogging simulation, a fast and precise simulation method for urban waterlogging based on U-Net super-resolution reconstruction was proposed. By using coarse accuracy waterlogging results as physical priors, a fast mapping of waterlogging distribution from coarse accuracy to fine accuracy was achieved. The Minzhi area of Shenzhen City was selected as the study area. Two sets of hydrodynamic simulation grids, coarse and fine, were constructed, combining terrain and its derived features as multi-channel inputs to train the deep learning model, and the simulation results were compared with the one-dimensional two-dimensional coupled hydrodynamic model. The results show that the super-resolution reconstruction method can accurately restore the spatial pattern and peak characteristics of ponding under most design rainstorm scenarios. The Nash efficiency coefficient generally exceeds 0.9, and the root mean square error is less than 0.15. Compared with the one-dimensional two-dimensional coupled hydrodynamic model, the efficiency of the simulation of the 2h rainstorm process is 50.71 times higher. With the increase of rainstorm return period, the super-resolution reconstruction method is more stable for the reconstruction of the overall ponding characteristics, but there is still a deviation in the local low-lying areas and areas with complex pipe network.

Key words: urban waterlogging simulation; super-resolution reconstruction method; deep learning model; hydrodynamic model; Shenzhen City

城市洪涝灾害已成为全球范围内城市发展面临的突出挑战。气候变化背景下极端暴雨事件的频繁发生,与快速城市化所带来的地表不透水化加剧叠加,使得内涝风险显著上升^[1]。据世界银行评估,中国每年因涝灾造成的直接经济损失约占 GDP 的

1%^[2]。相关研究表明,在超过 90% 城市中,城市化对洪涝危险具有主要正向贡献,而气候变化下的极端降雨演变趋势进一步放大了这一风险^[3-4]。典型案例包括 2021 年郑州“7.20”特大暴雨、2023 年京津冀特大暴雨等,均造成人员死亡失踪,并导致地

基金项目:国家自然科学基金项目(52579011);鄂尔多斯市科技重大专项项目(ZD20232323)

作者简介:陈文杰(1991—),男,副教授,博士,主要从事水文水资源研究。E-mail:wjchen@scau.edu.cn

通信作者:梅超(1991—),男,高级工程师,博士,主要从事城市水文与智慧水利研究。E-mail:meichao@iwhr.com

铁、道路、电力系统严重受损。刘家宏等^[5]的研究指出,特大城市在外洪与内涝灾害链的耦合中表现出复杂的系统联动特征。2023—2025 年全球多国和地区多次打破历史降雨纪录,极端暴雨事件频繁发生,包括韩国、中国香港、日本等。在城市化和气候变化双重驱动下,强降雨愈发集中、突发性增强、频次升高,传统防洪排涝体系在现有条件下的应对存在不足,亟待进一步发展高效、精准的洪涝模拟和预测方法,以提升城市防灾减灾能力。

城市洪涝预警是提升城市防灾减灾能力的重要非工程措施之一,国内外已经有了成熟的水文水动力模型,且能支持大尺度河流型洪水的应急管理^[6-7]。此类模型基于精细化的物理过程和数学公式,通过高程、土地利用和建筑物布局等数据模拟降雨、地表产汇流等水文水动力过程,具体可分为单一的水文、水动力模型和水文水动力耦合模型^[8]。在城市洪涝模拟研究中,水文模型和水动力模型各有侧重。常用的水文模型包括新安江模型、SCS-CN 方法等,其整体计算效率较高,参数物理意义明晰,适用于大尺度降雨与径流过程的模拟,但难以直接反映城市地表积水的动态演进和空间分布^[6,9]。相比之下,基于浅水方程的二维水动力学模型,如 LISFLOOD-FP、HEC-RAS 2D、TELEMAC-2D、FLO-2D 等,能够刻画水深、流速、流向等空间连续特征,在复杂地形及城市化区域的洪水过程模拟中被广泛应用。同时,为了兼顾地表径流和管网系统的交互,研究者们开发了一维-二维耦合或一体化的建模平台,如 MIKE URBAN、MIKE FLOOD、InfoWorks ICM,其在统一框架下处理降雨、入渗、地表汇流与管网溢流,多用于城市排水系统联动分析。然而这类模型需要详细的输入数据与复杂的参数率定,且在城市尺度下开展高分辨率计算往往消耗庞大的算力和时间,极大地限制了其在洪涝预警中的应用。有研究提出了一些解决方案,例如利用并行计算进行硬件加速或基于预模拟洪水场景进行估算^[10],但这些方法存在成本高昂、编程复杂的问题,或无法应对超标准的极端降雨情景。

近年来,机器学习模型的快速发展和学科之间的交叉应用为城市洪涝模拟提供了新的思路。其中深度学习模型在城市洪涝模拟与预测中展现出了显著优势。有研究者通过一维卷积神经网络(CNN)、二维 CNN 及其与长短期记忆(LSTM)等的耦合模型,实现了对降雨、地形、管网与土地利用等多源数据的高效特征提取,从而能够快速预测积水淹没水深与淹没范围。Kabir 等^[11]提出基于 CNN 的河流洪水快速预测方法,采用水动力模型的输出作为训

练数据,利用 CNN 快速预测洪水淹没深度,并验证了其可靠性,且结果表现优于支持向量机(SVR);Chen 等^[12]通过构建时空矩阵并融合 CNN 与 LSTM 提高了内涝预报的精度;Ouma 等^[13]则应用二维 CNN 实现了城市洪水易发性制图;林凯荣等^[14]提出基于深度学习的城市内涝积水水深预测模型,验证了深度神经网络在城市内涝模拟中的可行性与泛化潜力;瞿思敏等^[15]对比分析了机器学习与物理机制模型在实时洪水预报中的差异,结果显示数据驱动模型在短时洪水演进模拟中的响应速度明显优于物理模型,且在大多数情况下表现出较好的稳定性。尽管这些研究表明深度学习能够在效率和精度上超越传统的水文水动力模型,但其内在机理往往难以解释,即存在“黑箱”问题,限制了其结果的物理合理化与泛化能力。为了平衡计算效率与模型的可解释性,研究者们提出了融合物理先验的混合方法。一方面,康艳等^[16]提出了一种基于误差校正融合的自适应带宽洪水区间预报模型,将物理机制模型输出作为输入特征,利用深度学习模型对系统性误差进行校正,并结合自适应带宽核密度估计实现区间化预测,结果显示该模型在 90% 置信水平下的预测区间覆盖率超过 92%,兼具物理模型的可解释性与数据驱动模型的高精度特征;另一方面,研究者尝试在二维水动力计算框架中引入深度神经网络,实现从低分辨率到高分辨率的映射,以粗网格水动力模型快速生成低分辨率的城市内涝积水结果,再通过深度学习执行“从粗到细”的超分辨率重建,将物理模型的结构约束与数据驱动的细节恢复优势相结合,从而在保持物理约束的基础上恢复细节信息。在后者框架下,粗网格解承担降雨与径流等物理关系之间的刻画,深度网络学习跨尺度映射以复原细尺度积水水深,从而在数十秒量级的时效内,逼近高分辨率数值解的空间细节与演进过程^[17]。例如,Song 等^[18]提出的模型将粗网格水动力模拟与 Dense U-Net 结构结合,在复杂城市场景中展现出较好的稳定性和效率;Choi 等^[19]提出的模型将粗网格水动力模拟与提出的 FLO-SR 框架进一步验证了 CNN 在提升二维水动力模拟空间分辨率方面的潜力,并指出在模型中嵌入水动力约束对于提高泛化性和可解释性具有重要意义。这一思路既显著缓解了计算瓶颈,又通过“物理先验+学习映射”的方式降低了“黑箱”风险,为复杂城市场景的快速内涝评估提供了可操作的技术路径。

基于此,本文提出一种基于 U-Net 超分辨率重建的城市内涝快速精细模拟方法(以下简称“超分辨率重建方法”),利用粗精度耦合水动力模型与地

形特征数据,通过端到端训练建立粗精度到细精度积水结果的映射关系,在缩短模拟时间的同时,保持对淹没范围与积水峰值的还原度,并与一维-二维耦合水动力模型(以下简称“1D-2D 水动力模型”)模拟结果进行对比,以期为城市洪涝灾害管理提供参考。

1 研究区概况与数据来源

1.1 研究区概况

本文选取深圳市民治片区为研究区,位于龙华区东南部(22° 37' N, 114° 02' E),占地面积约 30.6 km²,地势整体平坦,地表以低丘陵和台地为主,呈南高北低走势。研究区属南亚热带季风气候,雨季集中,暴雨频发。经查《广东省水文图集》,研究区多年平均降水量为 1 722 mm,年际变化大,且年内分配极不均匀,主要集中在 4—9 月,约占全年降水量的 85%。研究区城市化程度高、建筑密集、交通设施复杂,由于地形低洼与排水压力大,历史上曾多次出现内涝现象。研究区具备典型的洪涝风险特征,且地理信息数据和降雨气象数据较完整,为开展城市内涝模拟与快速预测研究提供了理想条件。

1.2 数据来源

本文基础数据包括 DEM、管网、遥感影像、土地利用数据。其中,DEM 数据由研究区内实测高程点构建 TIN 模型后插值得到,实测高程点垂向精度优于 0.10 m,满足 10 m 细网格水动力计算所需的精度要求;管网数据根据研究区管网 CAD 数据图分析得到,将管线和沟渠概化为同一排水系统,不同类型附属物除了排水出口,统一概化为节点;遥感影像数据

基于 Google Earth 截取的研究区卫星遥感图得到,通过影像配准工具配准遥感图坐标,并导入 ArcGIS 中,使截取的研究区影像与矢量要素类坐标系统一致,该影像较清晰,能通过肉眼清楚分辨地物特征,通过手动提取获取道路和建筑物分布数据,并以 .shp 格式保存;土地利用数据基于 GIS 平台的影像分析功能得到,对研究区遥感影像数据图进行人机交互式的监督分类,对图像中的各种类型用地进行判读识别,提取研究区的土地利用类型。

2 研究方法

2.1 技术框架

本文利用 U-Net 对研究区地表网格上粗网格到细网格积水峰值的映射关系进行学习,并依据水动力模型模拟获得的网格上的积水信息,结合监督式深度学习超分辨率算法学习暴雨情景下各网格积水峰值的映射关系,实现对粗-细网格水深关系建模,在保持计算效率的同时快速生成精细洪水预测结果。为了充分利用地形信息,在输入端除粗网格水动力模拟结果外,额外拼接了 DEM 及其衍生的坡度、坡向、曲率 3 类静态栅格,共同作为多通道特征辅助网络学习。技术框架如图 1 所示。

2.2 城市洪涝数值模型

2.2.1 模型构建

基于 IFMS/Urban 平台构建 1D-2D 水动力模型,IFMS/Urban 平台包括一维河网、城市管网、二维地表水动力 3 个模块,支持一维-二维耦合计算。一维河网模型即 SWMM,城市管网部分与 SWMM 原理兼容,能够进行模型和数据层面的耦合交换^[20-21]。

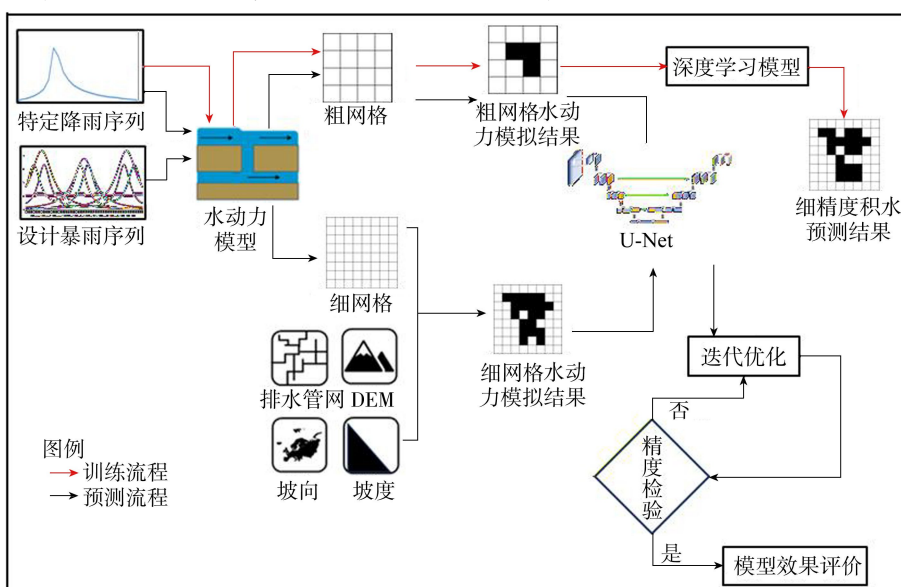


图 1 技术框架

Fig. 1 Technical framework

一维部分采用完整的非恒定流圣维南方程描述管网中水流的传输行为,涵盖检查井、排水管、溢流口等基础构筑物;二维部分基于浅水方程模拟地表降雨汇流、积水扩散与流速分布,充分考虑地形起伏与下垫面特征;一维部分与二维部分通过雨水口或井盖等节点实现动态连接,允许水体在地表与管网之间双向交换;地表降雨强烈时雨水汇入管网,管道超负荷运行时水反涌至地表形成积涝。一维与二维的耦合遵循质量与动量守恒原则,确保模拟的水力过程连贯、稳定且贴近实际城市排涝响应。

子汇水区划分采用泰森多边形法,利用监督分类提取用地类型,将研究区划分为绿地、裸地、水体、硬地4种类型,并基于栅格数据管理和分区统计工具,对各子汇水区的不透水率进行计算,进而获得较高精度的子汇水区不透水参数。将研究区进行概化,得到3769个节点、5855条管道及25个出水口,如图2所示。对研究区进行网格划分,细精度四边形网格分辨率为10 m×10 m,粗网格分辨率为100 m×100 m,最终得到细网格数为192745,粗网格数为2589,如图3所示。

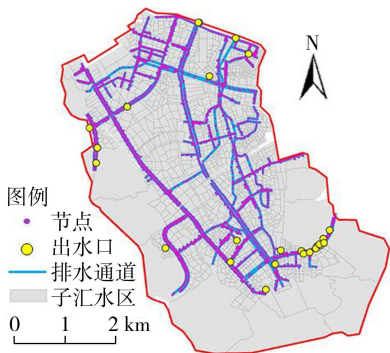


图2 研究区概化结果

Fig. 2 Generalization results of study area

SWMM构建过程详见文献[22],主要参数主要包括曼宁系数、洼蓄深、最大入渗率、稳定入渗率、衰减系数等,依据《SWMM用户手册》中参数的取值范

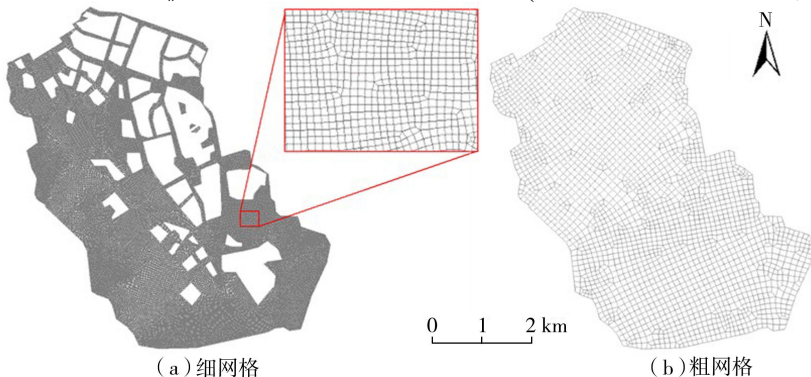


图3 研究区网格划分

Fig. 3 Grid division in study area

围,参考相关研究成果^[23]确定具体参数值,不透水区曼宁系数为0.011、透水区曼宁系数为0.24、不透水区地表洼蓄深为2.5 mm、透水地表洼蓄深为5.0 mm、不透水区无洼不透水面积比例为0.25、最大下渗率为78.1 mm/h、最小下渗率为3.30 mm/h、衰减系数为3.35。

选取研究区的实测暴雨过程验证1D-2D水动力模型的模拟精度,该场次暴雨具有典型的强度大、历时集中等特征,且积水点资料较完整。1D-2D水动力模型模拟所得的主要涝点最大积水深与实测积水深进行对比,结果如表1所示,可见相对误差均小于20%,在合理范围内,表明构建的1D-2D水动力模型能够较好地刻画研究区积水范围及峰值特征。

表1 1D-2D水动力模型模拟结果与实测值对比

Table 1 Comparison between simulation results of 1D-2D coupled hydrodynamic model and measured values

涝点位置	实测水深/cm	模拟水深/cm	相对误差/%
民治河边梅花新园	130	118	10
布龙路与人民路交会处	60	59	2
民乐天桥	70	72	3
上塘东路南二巷	100	80	20
临龙路	40	39	3
梅坂大道万家灯火	60	50	20

2.2.2 情景设置及训练数据集生成

由于研究区实测暴雨资料缺少,本文结合研究区实际暴雨特征,采用设计暴雨作为水动力模型的输入。参考Zhang等^[24]的研究,结合1950—2010年研究区降水资料,设计8种暴雨雨型,包括:早单峰(I型)、中单峰(II型)、晚单峰(III型)、双峰靠前(IV型)、双峰一前一后(V型)、双峰靠后(VI型)、均匀降雨(VII型)、波浪降雨(VIII型)。设计暴雨时长取2 h,暴雨重现期分别取1、2、5、10、20、50、100、500 a,暴雨强度公式采用深圳市气象局2024年5月公布的版本(式(1))。计算不同暴雨重现期的降水量,结合不同设计雨型,生成64种暴雨情景(1a-VI表示暴雨重现期为1 a的双峰靠后型

设计暴雨过程,以此类推)。暴雨重现期为 20 a 的 8 种设计暴雨过程如图 4 所示。

$$i = 8.701(1 + 0.594|gp)/(t + 11.13)^{0.555} \quad (1)$$

式中: i 为降雨强度; p 为暴雨重现期; t 为降雨历时。




图 4 暴雨重现期为 20 a 的 8 种设计暴雨过程

Fig. 4 8 design rainstorm processes with rainstorm return period of 5 a

将生成的 64 场设计暴雨过程输入构建的 1D-2D 水动力模型,模拟得到研究区两种不同精度网格的积水深度和积水位置。通过构建规则渔网进行空间重采样与赋值,形成规则化的规整矩阵,方便后续深度学习模型的输入和读取,将粗精度模拟结果赋值于 68×65 的方形渔网,细精度模拟结果赋值于 680×650 的方形渔网。基于粗网格的模拟结果通过简单最近邻上插值获得与基于细网格模拟结果相同像元的结果图,即 680×650 的粗精度细尺寸水动力模拟结果。

由于模拟网格数量大,为提升模型训练效率,对获得的矩阵网格进行滑块切片,每个暴雨情景切分为 306 个 128×128 的子块。同时,在保证静态通道同步变换的前提下,进行数据增强,增加模型训练样本及提升模型的泛化能力和鲁棒性,共获得 156 672 个子块。

2.3 超分辨率重建方法

城市洪涝积水深度受地形、排水条件和下垫面的影响,其空间分布呈连续变化并在局地低洼区域形成峰值,在进行超分辨率重建时,需要在保持空间结构连贯性的条件下对多尺度特征进行提取。U-Net 的对称编码-解码结构与跳跃连接能够在提高分辨率的同时保留浅层边界信息,减少深层重建阶段的细节损失,在连续场预测中具有更高的稳定性和空间一致性,在边界保持与峰值恢复方面更具优势^[16-18]。基于 U-Net 结构的超分辨率重建方法主要用于将粗精度水深图重建为细精度水深图,实现空间信息的细节恢复与精度提升。该方法融合了图像超分辨率的残差学习思想和地形先验特征输入,通过端到端训练获取粗精度与高精度之间的非线性映射关系,属于典型的回归型单图像超分辨率框架。具体来说,对于给定的粗精度输入 X ,利用学习函数

f_{θ} 来预测其对应的细精度输出 \hat{Y} ,即:

$$\hat{Y} = f_{\theta}(X) \quad (2)$$

为提升训练效率与重建质量,引入残差超分辨率机制,用于降低模型学习的复杂度。即不直接预测高分辨率图 Y ,而是预测其与低分辨率输入之间的差值 R ,进而得到 \hat{Y} :

$$\hat{Y} = \sigma(X + \hat{R}) \quad (3)$$

式中: \hat{R} 为网络预测的残差图; σ 为激活函数,用于确保输出水深非负。

采用 U-Net 作为核心架构,其具有对称的编码器-解码器结构和跳跃连接。编码器用于提取多尺度特征,解码器通过反卷积上采样逐步恢复空间分辨率,跳跃连接则将浅层特征传递到解码器以保留空间边界信息,有效防止细节损失。

基于 U-Net 结构的超分辨率重建方法能够融合 5 通道信息输入,包括粗网格水动力模拟结果、DEM、坡度、坡向、曲率,捕捉粗-细网格水深的映射特征,其框架由三层卷积编码器+桥接层+三层转置卷积解码器+残差输出层组成。图 5 为 U-Net 架构示意图。

超分辨率重建方法的关键环节包括:

a. 训练轮次设置。研究前期尝试了 300、600、900 的训练轮次数进行试验,验证集结果显示训练轮次为 600 时收敛最充分、性价比最高且稳定性良好,故本文训练轮次设为 600。

b. 学习率设置。本文采用分段常数衰减策略,定义了 Piecewise Constant Decay 学习率调度器。该调度器在训练过程中根据训练轮次的变化调整学习率,具体设置为:在第 200 个和 400 个轮次时分别调整学习率,从最初的 1×10^{-4} 降低到 5×10^{-5} 再降到 1×10^{-5} ,有助于在训练初期快速收敛,并在后期稳定训练过程。

c. 损失函数设置。本文所处理的城市积水整体呈现中低水深占比较高、局部低洼区存在明显长尾极值的分布特征。L2 损失在存在长尾极值时容易放大个别异常点的梯度贡献,从而影响主流区域的拟合效果,而 L1 损失在抑制极端误差方面更具优势,更有利于保证模型训练过程的稳定性和结果的物理合理性。故本文采用结合掩膜损失机制调整的 L1 损失,该掩膜基于细网格水动力模型模拟水深值是否为 0 生成,仅对非 0 值区域计算损失,从而避免了对无效区域的误导性训练,集中优化模型在有效数据上的表现。

本文采用纳什效率系数(NSE)和均方根误差(RMSE)评价基于 U-Net 的超分辨率重建方法的性能。NSE 用于衡量预测值与实测值的相似性,能够

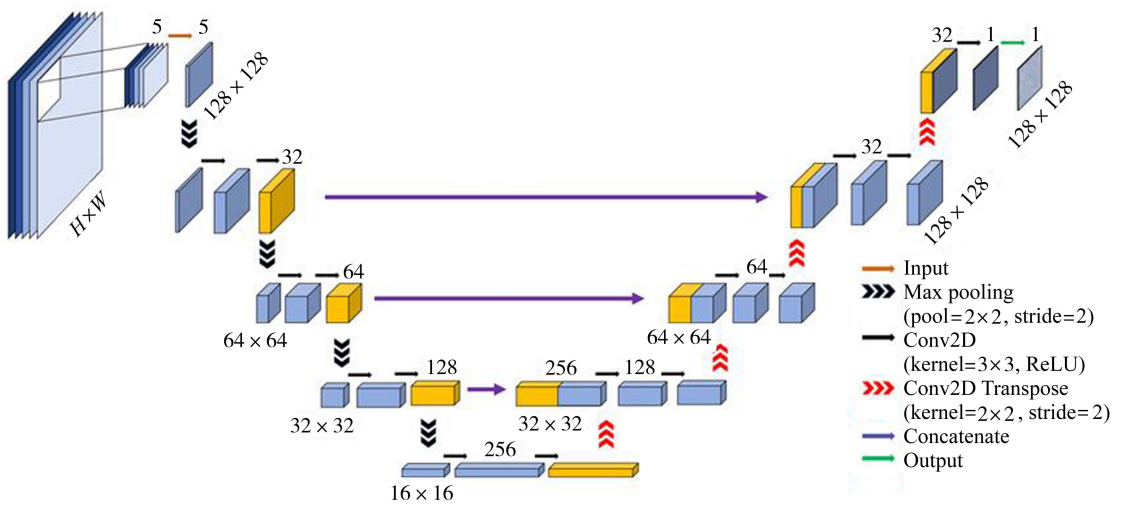


图 5 U-Net 架构示意图
Fig. 5 U-Net architecture diagram

全面评估模拟数据的准确性,取值范围为 $(-\infty, 1]$,值越接近 1 表示效果越好;RMSE 反映预测值偏离实测值的平均程度,取值范围为 $[0, +\infty)$,值越小结果精度越高。

3 结果与分析

基于生成的 64 场设计暴雨过程和研究区 DEM 数据,将 1D-2D 水动力模型的输出结果划分为训练集、验证集、测试集,分别为 48、8、8 场。额外设置 4 场雨型、峰值雨强、持续时间方面差异显著的实测 2 h 暴雨过程(实测 1~4)作为补充测试集,雨型分别为单峰型、双峰型、单峰型、单峰型,峰值雨强分别为 21.6、19.4、22.0、42.5 mm/min,累计降水量分别为 250、270、350、450 mm。训练集中的粗精度样本作为 U-Net 预测的主要参考;细精度样本作为 U-Net 的输出目标,同时也是 U-Net 训练时的最主要监督指标;根据 DEM 生成的坡度、坡向和曲率 3 种地形特征数据额外辅助 U-Net 训练。验证集用于检验 U-Net 训练的精度是否达标,NSE 平均为 0.911,最高为 0.935, RMSE 平均为 0.091,最低为 0.074,均处于较高水平,表明所构建的 U-Net 在还原细网格积水峰值这一任务上发挥良好。

3.1 最大积水深度

利用超分辨率重建方法对测试集的 12 场暴雨过程进行模拟验证。将 1D-2D 水动力模型模拟结果作为最大积水深度的真实值,超分辨率重建方法输出值作为最大积水深度的模拟值,得到散点图如图 6 所示。从整体分布特征来看,绝大部分散点均较为集中地分布在 45° 理想线 $y=x$ 附近,这表明构建的模型在不同降雨情景下均能较好地拟合水动力模型模拟结果。拟合方程的斜率介于 0.92~1.00,

说明超分辨率重建方法预测结果与 1D-2D 水动力学模型保持较高一致性。随着暴雨重现期的增加,拟合精度逐渐提升,NSE 从 0.8867 提升至 0.9808,而 RMSE 则由 0.2883 降至 0.0851,表现出随着降雨强度增大模型预测更加稳健的趋势。特别是在暴雨重现期为 50、100、500 a 等极端情景中,超分辨率重建方法在多数情景下与 1D-2D 水动力模型结果高度一致,显示其在应对强降雨与严重积水条件下的高适用性。相比之下,在暴雨重现期为 1、2 a 等低强度情景中,超分辨率重建方法存在一定低估现象, RMSE 较高,轻微积水情景下的不确定性更为显著。整体而言,超分辨率重建方法在设计暴雨下表现出良好的普适性和随降雨强度增强的鲁棒性。与设计暴雨情景相比,历史实测降雨下的预测结果表现出更复杂的不确定性。实测 1 事件中,拟合斜率偏高,NSE 为 0.8625, RMSE 为 0.2382,超分辨率重建方法在该次暴雨事件中存在高估现象,且误差水平明显大于多数设计暴雨情景;实测 2 事件中,超分辨率重建方法精度有所改善,NSE 提升 0.9166, RMSE 降至 0.1776,表明其在再现积水峰值分布时更为可靠;实测 3 事件中,拟合斜率为 1.15, NSE 为 0.9025, RMSE 为 0.2112,整体精度依然保持较高水平,但相较实测 2 略有下降;实测 4 事件中,拟合斜率偏高,NSE 为 0.8769, RMSE 为 0.3531,出现更明显的高估趋势和更大的离散性,反映出该场暴雨具有更强的不规则性与极端性。超分辨率重建方法在历史实测暴雨事件下的表现略差于设计暴雨情景,反映了实际降雨过程更强的空间不确定性及复杂性。同时,超分辨率重建方法仍能保持较高精度也侧面反映了该方法在真实降雨条件下的泛化能力和应用潜力。

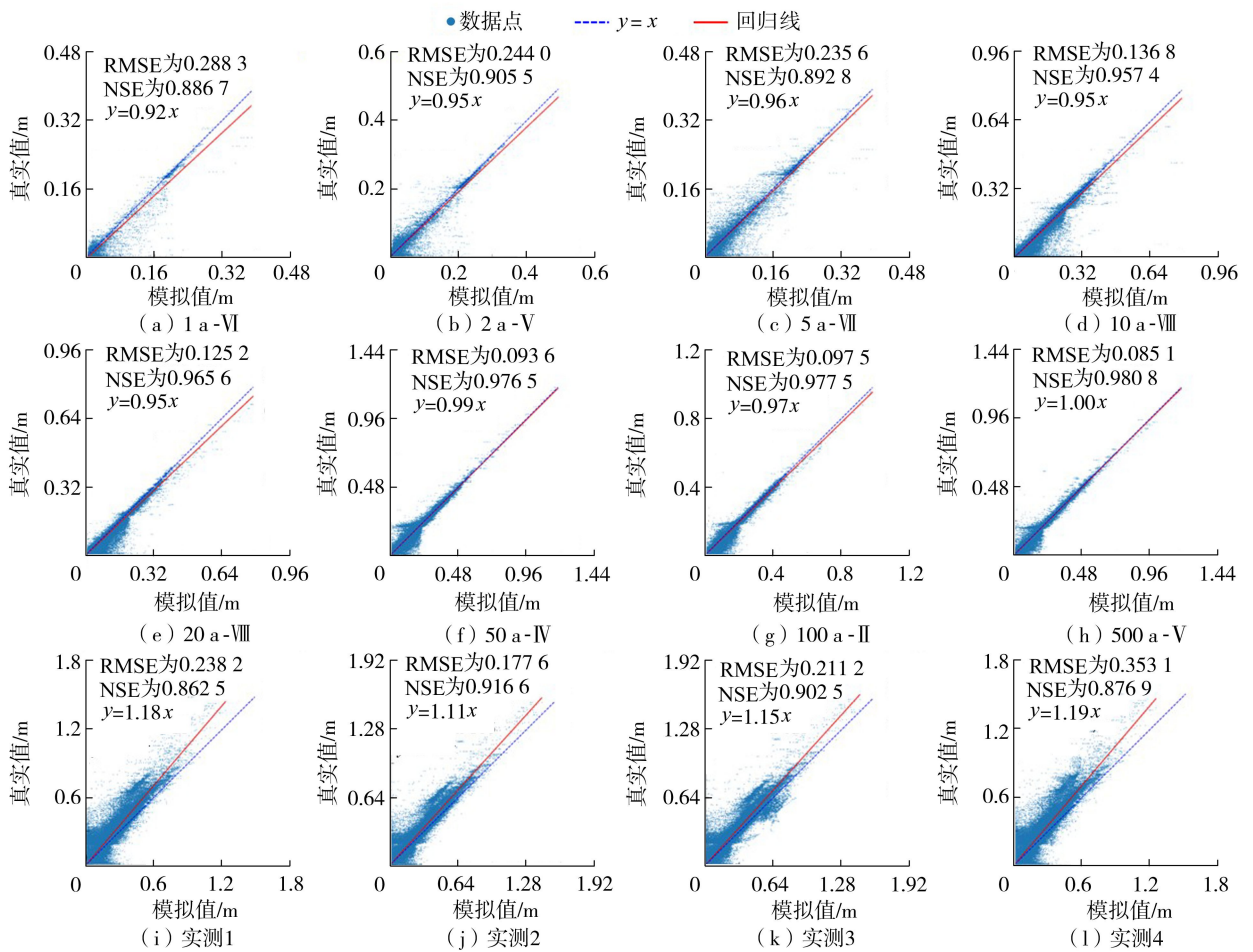


图 6 最大积水深度真实值与模拟值的散点图

Fig. 6 Scatter plot of real and simulated values of maximum waterlogging depth

3.2 积水深度空间分布

利用超分辨率重建方法对测试集的 12 场暴雨过程进行模拟,得到积水深度的空间分布,并统计其与 1D-2D 水动力模型模拟值的绝对误差,如图 7、图 8 所示。表 2 为不同积水深度超分辨率重建方法与 1D-2D 水动力模型模拟值的绝对误差累计。

由图 7(a)~(c)和图 8(a)~(c)可见,在暴雨重现期为 1~5 a 的情景下,超分辨率重建方法模拟结果显示积水主要集中在研究区东北部和中部的低洼区域,随着暴雨重现期增大,局部积水峰值逐渐增加。对应的绝对误差空间分布表明,超分辨率重建方法整体趋势与 1D-2D 水动力模型一致,绝对误差较小,主要分布在局部零星区域。超分辨率重建方法在中小暴雨重现期下,能够较为稳定地反映整体积水格局,尽管有不少零星误差格点,但局部偏差对整体影响有限。结合表 2,这一阶段超过 70% 的格点绝对误差小于 2 cm,绝对误差高于 10 cm 的占比不足 6%,可见超分辨率重建方法在中小暴雨重现期下的精度较为稳定。

由图 7(d)~(f)和图 8(d)~(f)可见,当暴雨重

表 2 不同积水深度超分辨率重建方法与 1D-2D 水动力模型模拟值的绝对误差累计

Table 2 Absolute error accumulation of super-resolution reconstruction method and 1D-2D coupled hydrodynamic model simulation values for different waterlogging depth

暴雨情景	绝对误差累计占比/%				
	0	0~ <0.02 m	0.02~ <0.06 m	0.06~ <0.1 m	≥0.1 m
1 a-VI	3.36	77.93	88.97	92.82	100
2 a-V	3.39	74.62	89.52	93.32	100
5 a-VII	3.41	75.96	89.67	93.34	100
10 a-VIII	3.12	80.96	91.54	94.53	100
20 a-VIII	3.16	79.64	90.68	93.88	100
50 a-IV	3.20	79.09	89.21	92.38	100
100 a-II	3.17	78.73	89.44	92.72	100
500 a-V	3.16	78.53	88.84	92.03	100
实测 1	3.11	75.40	86.03	89.68	100
实测 2	3.13	76.58	87.16	90.58	100
实测 3	3.12	75.58	88.64	91.26	100
实测 4	3.21	78.31	86.13	90.95	100

现期增大,超分辨率重建方法模拟结果显示积水范围明显扩大,南部和地势平缓区域逐渐产生积水汇聚,积水深度整体呈增加趋势。绝对误差分布情况表现出与前期不同的特征,不再是零散分布,而是更

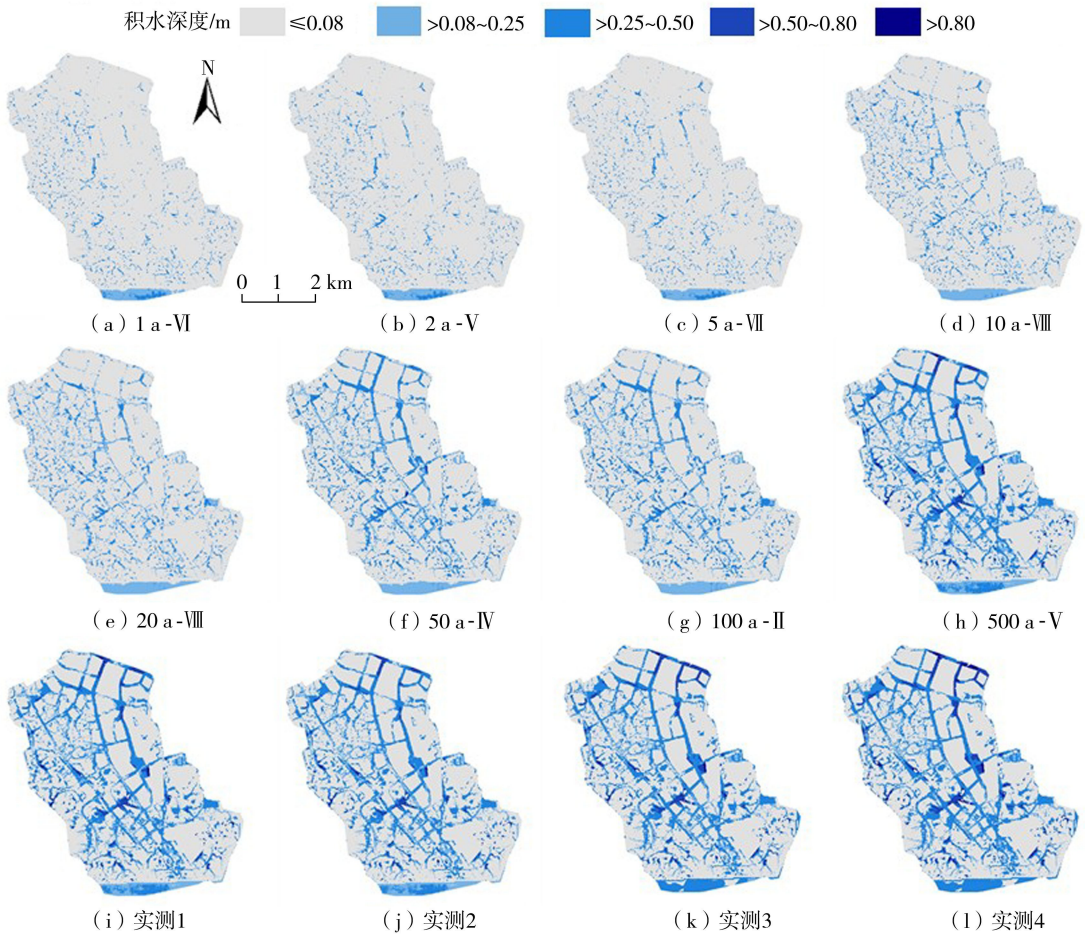


图7 超分辨率重建方法模拟的积水深度空间分布

Fig. 7 Spatial distribution of waterlogging depth simulated by super-resolution reconstruction method

为集中地出现在道路及建筑密集区域。在此阶段,尽管局部偏差有所增加,但表2中绝对误差累计结果显示,绝大部分格点的绝对误差仍然控制在2 cm以下,整体趋势未受到显著影响。

由图7(g)(h)和图8(g)(h)可见,在极端暴雨情景下(100、500 a),超分辨率重建方法模拟结果呈现大面积积水,部分交通要道及南部低洼区域尤为明显。对应的绝对误差分布显示,局部差异进一步放大,尤其是在排水网络复杂及高密度建筑区域。从绝对误差累计来看,超过70%格点的绝对误差依然小于2 cm,仅少数格点超过10 cm。可见在极端暴雨情景下,超分辨率重建方法依然可以合理反映总体积水情况。

由图7(i)~(l)和图8(i)~(l)可见,在4场历史实测暴雨情景下,超分辨率重建方法模拟结果再现了短历时强降雨导致的研究区积水深度分布情况。对应的绝对误差空间分布表现出更强的局地性,排水节点及交通交汇处较高的绝对误差尤为集中。结合表2,2场实测暴雨情景下约75%的格点绝对误差控制在2 cm以内,但局部地区超过10 cm的情况依然存在。可见在真实暴雨情景下,超分辨率

重建方法在预测整体积水情况方面具有较高稳定性,但受管网运行、地表径流等复杂影响,在局部位置的预测精度难以完全匹配。

综上,随着暴雨重现期的逐步增大,超分辨率重建方法模拟的积水深度空间分布呈现出由局部聚集向整体扩展的演变规律。绝对误差在低强度降雨情景下,多为离散分布;在中强度降雨情景下,偏差逐渐集中于南部低洼区和高密度建筑区域;在极端降雨情景下,这些局部差异被进一步放大,表现为明显的高估或低估。总体而言,超分辨率重建方法在大尺度空间格局刻画上具有较高稳定性,但在局部复杂的城市化环境中仍存在改进空间。

3.3 模型计算时效性

利用超分辨率重建方法和1D-2D水动力模型模拟测试集12场暴雨情景过程,模拟耗时统计结果如表3所示。本次仅模拟了2h暴雨过程,随着研究区大小、网格数量、暴雨时长等要素的增加,1D-2D水动力模型的复杂度大幅增加,从而显著延长模拟耗时。超分辨率重建方法的深度学习模型在前期花费大约11h训练模型,在后续模拟时仅依靠粗网格水动力模型的输出结果,在1 min以内便能得到2h

绝对误差/m ≤0.02 >0.02-0.06 >0.06-0.10 >0.10

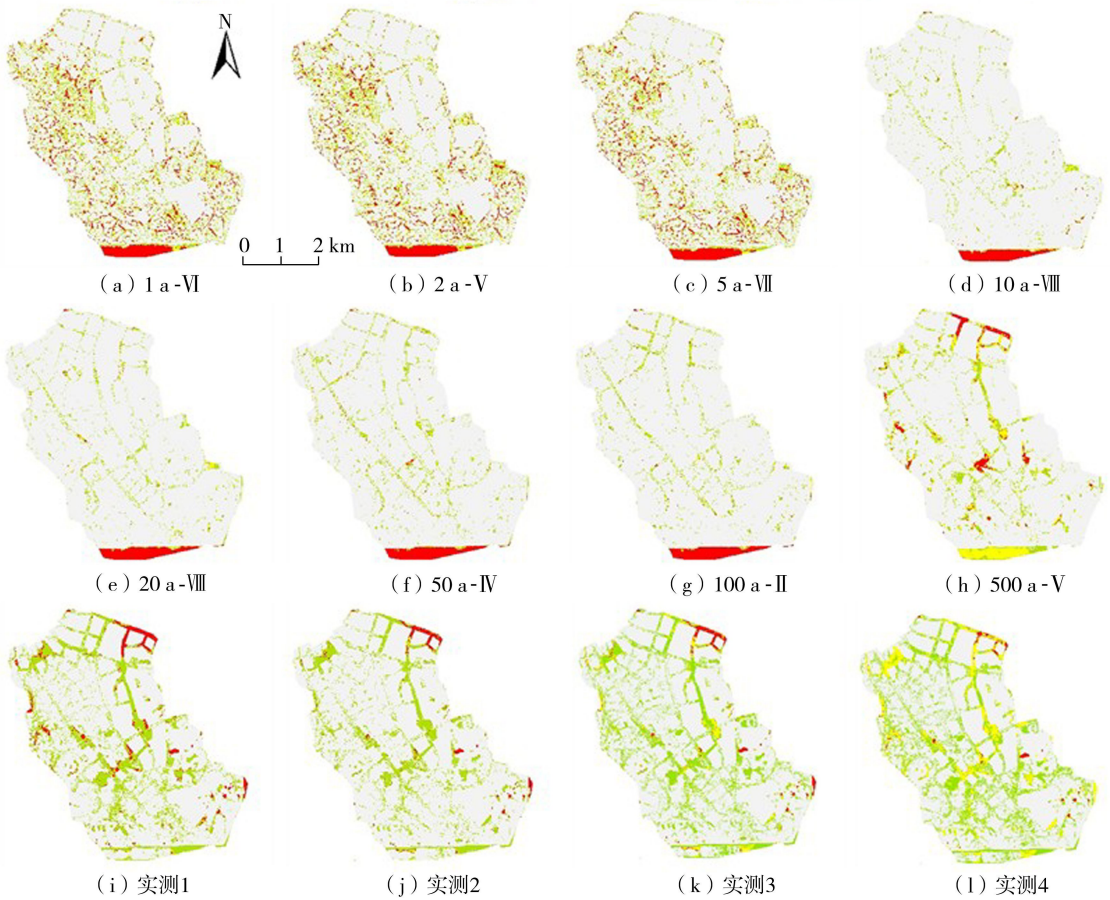


图 8 超分辨率重建方法与 1D-2D 水动力模型模拟积水深度的绝对误差空间分布

Fig. 8 Absolute error spatial distribution of simulated waterlogging depth of super-resolution reconstruction method and 1D-2D coupled hydrodynamic model

表 3 不同模型的模拟耗时统计结果

Table 3 Statistical results of simulation time for different models

暴雨情景	1D-2D 水动力模型耗时/s	超分辨率重建方法耗时/s		提升倍率
		粗网格水动力模型	深度学习模型	
1 a-VI	2634	47	8	47.89
2 a-V	2535	46	8	46.94
5 a-VII	2621	48	8	46.80
10 a-VIII	2583	46	8	47.83
20 a-VIII	2663	49	8	46.71
50 a-IV	2719	51	8	46.08
100 a-II	2686	50	8	46.31
500 a-V	2704	52	8	45.06
实测 1	2874	49	8	50.42
实测 2	2634	50	8	45.41
实测 3	2789	47	8	50.71
实测 4	2643	49	8	46.37

暴雨过程的积水深度模拟结果。相较于使用 1D-2D 水动力模型,使用粗网格水动力模型先获得较低精度的积水淹没结果,再通过深度学习模型快速模拟该暴雨情景下的较高精度积水深度结果,这一方法

在保证基本产汇流机理的合理性的前提下,有效提升了模拟计算效率,在测试集中计算效率最大可提升 50.71 倍,表现出较高的计算效率。

同时,超分辨率重建方法的深度学习模型部分仅负责由低精度积水结果还原至高精度积水结果这一步骤,计算耗时不会随模拟暴雨时长增加而增加,始终维持在 10s 以内。1D-2D 水动力模型和粗网格水动力模型的模拟耗时会随着模拟暴雨时长的增加而增加,但 1D-2D 水动力模型耗时会比粗网格水动力模型增长得更快,两者之间的计算效率会更加显著。可见,通过粗网格水动力模型结合深度学习模型的途径在城市内涝模拟中具有显著优势。

3.4 讨论

本文构建的超分辨率重建方法在多数降雨情景下能够较好地还原最大积水深度和积水深度的空间分布,验证了数据驱动方法在城市内涝快速模拟中的可行性。结果显示,超分辨率重建方法在中强度降雨情景下表现稳定,在暴雨重现期为 1、2a 的低强度降雨情景和实际暴雨情景时存在一定误差。表明超分辨率重建方法能够应对极端条件,但在复杂实

实际情景下仍有改进空间。从整体表现来看,超分辨率重建方法的优势在于计算效率高、空间分布还原度较好、对强降雨的适应性强,能够作为传统水动力模拟的快速替代方案。然而,局部模型仍存在偏差,尤其在低洼地带和排水不均衡区域。历史实测降雨情景下的不确定性也提示超分辨率重建方法对真实水文过程的刻画仍不充分,外部因素,如管网运行和垫面特征,未得到有效体现。粗网格大小的选取也尤为关键,既关系到耦合水动力模型的计算效率,又关系到训练数据的质量。随着网格尺寸增大,局部地形细节被平滑化,低洼汇水区在平均化过程中消失,从而减弱积水形成;较大的网格使坡降整体增大,径流加快下泄,管网与地表交换过程被弱化,加之数值耗散效应增强,水流被过度扩散,峰值被削减,最终表现为水动力模型模拟的积水深度和范围均有所下降,这会导致错误的结果,进而误导超分辨率重建方法的深度学习模型。本文研究区面积为约 30.6 km^2 的城区,在前期试验中曾采用 200 m 粗网格与 10 m 细网格的组合。试验结果显示, 200 m 粗网格将多个街区合并为单一单元,局地洼地、道路凹槽以及细尺度坡降等关键微地形完全丢失,导致重建结果呈现峰值难以恢复、积水分布过度平滑及边界模糊等现象,无法满足精度要求。若将粗网格进一步缩小至 50 m 或者更小尺度,虽然地形表达能力有所改善,但在仅 30.6 km^2 的区域内,粗网格数量仍然过大,计算加速效果十分有限,难以体现快速模拟的核心优势。因此,本文研究采用 10 m 细网格与 100 m 粗网格、尺度比为 $1:10$ 的尺度组合。研究成果与He等^[17]的研究结果一致,该研究指出当细网格与粗网格的尺度比例维持在约 $1:8$ 至 $1:15$ 之间时,粗网格仍能准确保留主导性的地形梯度和汇流格局,使跨尺度映射关系保持稳定且具备可学习性;若粗网格进一步加大,地形细节将被过度平滑,细尺度洪涝重建将出现峰值偏移与积水边界模糊等不稳定现象。

将超分辨率重建方法应用于其他不同地形特征的新区域时,需要根据研究区的耦合水动力模型重新训练,这也在一定程度上限制了该方法的实用性。若想提升超分辨率重建方法对新区域的泛化能力,应使用更深网络结构的模型和包含大量地形的更庞大的训练数据。后续研究中应进一步解决超分辨率重建方法在低强度降雨情景和极端降雨下的不确定性,提升对局部低洼和排水复杂区域的预测能力。针对粗网格尺寸,可结合研究区尺度优化网格划分策略,丰富训练输入数据维度,引入排水管网、土地利用和垫面特征等,以增强对真实积水机理的描述。

4 结 论

a. 本文提出的超分辨率重建方法将物理先验引入深度学习框架,有助于降低“黑箱”风险。粗网格水动力模型有效保证了基本产汇流机理的合理性,而深度学习模型则通过跨尺度映射恢复细尺度空间细节。

b. 所提出超分辨率重建方法具有极高的计算效率。在细网格与粗网格的尺度比为 $1:10$ 的情况下,模拟效率与 $1\text{D}-2\text{D}$ 水动力模型相比最大可提升 50.71 倍。对于研究区 30.6 km^2 的范围,该方法模拟 2 h 暴雨过程时的计算时间可压缩至 1 min 以内,其中深度学习部分约为 10 s ,限制该方法最主要的因素为粗网格水动力模型的模拟耗时。随着模拟降雨时间的增加,相较于 $1\text{D}-2\text{D}$ 水动力模型的效率提升更加显著。

c. 所提出超分辨率重建方法能够以高精度预测不同暴雨情景下的积水深度峰值和淹没范围,在所有测试集中, $1\text{D}-2\text{D}$ 水动力模型和超分辨率重建方法在模拟结果上具有较高的拟合程度,其中暴雨重现期为 $5\sim 500\text{ a}$ 的降雨情景下,NSE值均超过 0.9 ,RMSE值基本小于 0.15 。在绝对误差统计中,约有 10% 以内的格点误差超过 10 cm 。当细网格与粗网格的尺度比例维持在 $1:10$ 以内,积水淹没峰值和淹没范围均能实现较高精度的预测。

参考文献:

- [1] 刘汀蓉,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))
- [2] Wishart M J, Wong T, Furnage B, et al. The gray, green, blue continuum: valuing the benefit of nature-based solutions for integrated urban flood management in China [R]. Washington: World Bank Group, 2021.
- [3] Tang Ziyi, Wang Pin, Li Yao, et al. Contributions of climate change and urbanization to urban flood hazard changes in China's 293 major cities since 1980 [J]. Journal of Environmental Management, 2024, 353: 120113.
- [4] 段亭亭,李鹏峰,邱顺添,等. 基于多源数据的长春市洪涝灾害应对能力评估与提升[J]. 河海大学学报(自然科学版), 2025, 53(6): 41-48. (Duan Tingting, Li Pengfeng, Khu S T, et al. Assessment and enhancement of flood disaster response capability in Changchun City based on multi-source data [J]. Journal of Hohai University

- (Natural Sciences), 2025, 53(6):41-48. (in Chinese))
- [5] 刘家宏,梅超,刘宏伟,等.特大城市外洪内涝灾害链联防联控关键科学技术问题[J].水科学进展,2023,34(2):172-181. (Liu Jiahong, Mei Chao, Liu Hongwei, et al. Key scientific and technological issues of joint prevention and control of river flood and urban waterlogging disaster chain in megacities[J]. Advances in Water Science, 2023, 34(2):172-181. (in Chinese))
- [6] 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, Zheng Yulei, 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))
- [7] Wen Zhiqun, Liang Xu, Yang Shengtian. A new multiscale routing framework and its evaluation for land surface modeling applications [J]. Water Resources Research, 2012, 48(8):W08528.
- [8] 邓成,夏军,余敦先,等.基于水文水动力耦合模型的深圳市典型区域城市内涝模拟[J].武汉大学学报(工学版),2023,56(8):912-921. (Deng Cheng, Xia Jun, She Dunxian, et al. Urban waterlogging simulation in a typical area in Shenzhen based on hydrological-hydrodynamic coupling model [J]. Engineering Journal of Wuhan University, 2023, 56(8):912-921. (in Chinese))
- [9] Rossman L A. Storm water management model user's manual version 5. 0 [R]. Cincinnati: US Environmental Protection Agency, 2010.
- [10] Henonin J, Russo B, Mark O, et al. Real-time urban flood forecasting and modelling-a state of the art[J]. Journal of Hydroinformatics, 2013, 15(3):717-736.
- [11] Kabir S, Patidar S, Xia Xilin, et al. A deep convolutional neural network model for rapid prediction of fluvial flood inundation[J]. Journal of Hydrology, 2020, 590:125481.
- [12] Chen Jian, Li Yaowei, Zhang Shanju. Fast prediction of urban flooding water depth based on CNN-LSTM [J]. Water, 2023, 15(7):1397.
- [13] Ouma Y, Tateishi R. Urban flood vulnerability and risk mapping using integrated multi-parametric AHP and GIS: methodological overview and case study assessment[J]. Water, 2014, 6(6):1515-1545.
- [14] 林凯荣,欧阳佳娜,马旭民,等.基于深度学习的城市内涝积水水深预测模型[J].水资源保护,2025,41(1):56-63. (Lin Kairong, Ouyang Jiana, Ma Xumin, et al. Prediction model of urban waterlogging water depth based on deep learning [J]. Water Resources Protection, 2025, 41(1):56-63. (in Chinese))
- [15] 瞿思敏,余裕,方正,等.机器学习模型与物理机制模型在长诏水库流域实时洪水预报中的比较研究[J].水资源保护,2025,41(5):73-78. (Qu Simin, Yu Yu, Fang Zheng, et al. Comparative study of machine learning model and physical mechanism model in flood forecasting of the Changzhao Reservoir Basin [J]. Water Resources Protection, 2025, 41(5):73-78. (in Chinese))
- [16] 康艳,艾慧茹,彭仁娟,等.基于误差校正融合模型的自适应带宽洪水区间预报[J].水资源保护,2025,41(5):106-114. (Kang Yan, Ai Huiru, Peng Renjuan, et al. Adaptive bandwidth flood interval forecasting based on error-corrected hybrid model [J]. Water Resources Protection, 2025, 41(5):106-114. (in Chinese))
- [17] He Jian, Zhang Limin, Xiao Te, et al. Deep learning enables super-resolution hydrodynamic flooding process modeling under spatiotemporally varying rainstorms [J]. Water Research, 2023, 239:120057.
- [18] Song Wenke, Guan Mingfu, Guo Kaihua, et al. Rapid flood inundation mapping by integrating deep learning-based image super-resolution with coarse-grid hydrodynamic modeling [J]. Engineering Applications of Computational Fluid Mechanics, 2025, 19(1):2481115.
- [19] Choi H, Woo H, Kim M, et al. FLO-SR: deep learning-based urban flood super-resolution model [J]. Journal of Hydrology, 2025, 661:133529.
- [20] 喻海军,马建明,张大伟,等. IFMS Urban 软件在城市洪水风险图编制中的应用[J].中国防汛抗旱,2018,28(7):13-17. (Yu Haijun, Ma Jianming, Zhang Dawei, et al. Application of IFMS urban software in urban flood risk mapping [J]. China Flood & Drought Management, 2018, 28(7):13-17. (in Chinese))
- [21] 杨立园,黄标,刘甲春,等.基于 SWMM-贝叶斯耦合方法的排水管网污染溯源[J].河海大学学报(自然科学版),2024,52(5):20-29. (Yang Liyuan, Huang Biao, Liu Jiachun, et al. Pollution source tracing in sewer networks based on a Bayesian-SWMM coupled approach [J]. Journal of Hohai University (Natural Sciences), 2024, 52(5):20-29. (in Chinese))
- [22] 黄国如,张灵敏,雒翠,等. SWMM 模型在深圳市民治河流域的应用[J].水电能源科学,2015,33(4):10-14. (Huang Guoru, Zhang Lingmin, Luo Cui, et al. Application of SWMM model in Minzhi River Basin of Shenzhen City [J]. Water Resources and Power, 2015, 33(4):10-14. (in Chinese))
- [23] 黄国如,李碧琦.深圳民治河流域低影响开发措施水文效应评估[J].水资源与水工程学报,2018,29(3):1-6. (Huang Guoru, Li Biqi. Hydrological effect evaluation of low impact development measures at Minzhi River Basin in Shenzhen [J]. Journal of Water Resources and Water Engineering, 2018, 29(3):1-6. (in Chinese))
- [24] Zhang Mingliang, Xu Menghua, Wang Zhaoli, et al. Assessment of the vulnerability of road networks to urban waterlogging based on a coupled hydrodynamic model [J]. Journal of Hydrology, 2021, 603:127105.