

陈厚霖,王加虎.基于机器学习的平原城市圩区内涝积水快速模拟方法研究[J].人民珠江,2026,47(3):41-53.

基于机器学习的平原城市圩区内涝积水快速模拟方法研究

陈厚霖,王加虎*

(河海大学,江苏 南京 210024)

摘要:近年来,江苏省常熟市城区在汛期频繁遭遇强降雨过程,局地积水严重,传统物理模型在应急响应中难以满足时效需求。为提升洪涝预测效率,亟须构建兼顾精度与速度的快速模拟方法。选取常熟主城区典型平原圩区,基于InfoWorks ICM构建一维管网-二维地表耦合模型,模拟12场不同强度降雨过程,提取高精度淹水结果作为样本。结合模拟数据,构建长短期记忆网络(Long Short-Term Memory, LSTM)用于关键节点水深序列预测,卷积神经网络(Convolutional Neural Network, CNN)用于淹水空间分布回归,实现数据驱动与物理建模的融合。模型在测试样本中预测精度较高, LSTM预测序列决定系数超过0.90, CNN预测图峰值误差控制在 ± 5 cm内,空间交并比(Intersection over Union, IoU)达到0.87,计算效率较ICM(Integrated Catchment Modeling)提升百倍以上。深度学习代理模型能有效提升城市内涝模拟响应速度,在区域尺度的快速预警与辅助决策中具备工程应用潜力。

关键词:城市内涝;洪涝模拟;机器学习;卷积神经网络;长短期记忆网络

中图分类号:TV14 **文献标识码:**A **文章编号:**1001-9235(2026)03-0041-13

近年来,全球气候变暖导致极端天气事件频发,这一现象引起了广泛关注^[1]。随着城市下垫面日益硬化、排水设施能力相对不足,城市洪涝形势更加复杂严峻。极端暴雨引发的城市内涝灾害往往具有突发性强、隐患点多、影响范围广、次生灾害多、损失巨大的特点。大量研究^[2-6]表明,暴雨内涝已成为全球范围内对人类生存和社会发展威胁最大的灾害之一。近年来中国超过一半的城市遭遇过不同程度的内涝事件。例如,北京“7·21”特大暴雨导致房山区中小河道堤防、水库等数千处水毁,直接经济损失约100亿元^[7];郑州2021年“7·20”特大暴雨造成市区严重积水及地铁隧道进水等灾害,导致380人伤亡、经济损失409亿元^[8]。这些事件暴露出城市排水防涝能力的不足,引起社会各界对城

市内涝问题高度关注。频繁出现的特大暴雨洪涝灾害已成为制约中国城市可持续发展的主要威胁之一。

平原河网地区地势低平、水系密布、坡降极小,雨水难以及时靠重力排出。长期实践中,人们在低洼区域周围筑堤建闸和泵站,形成封闭的“圩区”^[9]。由于水利工程体系复杂,所以平原河网城市内涝更具特殊性。常熟市位于长江三角洲冲积平原,地势低平,城区外围建有围堤和水闸构成防洪圈(俗称“大包围”),暴雨后易出现圩区内积水难以及时排除的情况。同时,大包围的抽排作业可能将大量城区积水转移至围堤外河网,造成外围河道水位骤升,对上下游区域形成顶托效应,增大沿线城市防洪压力^[10]。对于此类平原圩区城市,提高暴雨条件下排涝模拟与预报的时效性对其防灾减灾具有重要意义。

收稿日期:2025-06-23 修回日期:2025-09-01 网络首发日期:2025-09-12

作者简介:陈厚霖(1999—),男,硕士研究生,研究方向为城市洪涝、数值模拟。

通信作者:王加虎(1975—),博士,副教授,主要研究方向为分布式水文模型建模与应用相关内容、气候变化及人类活动的水文响应、参数优选与时空分布规律和应用、水文模型软件研发等。

联系作者:致信 rmzj@pearlwater.gov.cn,由期刊转接。

城市暴雨内涝的模拟与预报是城市防洪减灾最重要的非工程措施之一,可为防涝规划和应急响应提供科学依据^[11]。然而,构建既快速又准确的内涝模拟模型极具挑战性。传统上,城市内涝模拟主要依赖物理机理型数值模型,如SWMM(Storm Water Management Model,美国国家环境保护局开发的雨水管理建模软件,适用于一维管网及地表径流模拟);MIKE Urban(丹麦DHI公司开发的雨水系统模拟平台,支持雨污排水与二维地表耦合建模);InfoWorks ICM(英国Innovyze公司开发的集成城市雨洪模拟软件,支持一维管网与二维地表流耦合建模)等^[12]。此类模型通过求解非恒定流或浅水方程,细致描述“降雨-产流-汇流-积水”物理过程,在模拟精度上具有可靠性。然而高精度伴随高计算量,一次完整的暴雨过程模拟可能耗时数小时,难以满足实时预测和多方案快速评估的需要^[13-14]。突发暴雨下,决策者需要在短时间内获取各区域可能的积水深度与范围以采取措施,但完全依赖物理模型实时计算往往因耗时过长贻误战机。因此,探索更快速的城市洪涝模拟技术具有重要现实意义。

近年来兴起的机器学习和数据驱动方法为内涝模拟提供了新思路。机器学习模型(特别是深度学习中的卷积神经网络CNN(Convolutional Neural Network,一类深度学习模型,适合处理具有空间结构的数据,可自动提取图像中的空间特征)和长期记忆网络LSTM(Long Short-Term Memory,一种特殊的循环神经网络结构,通过引入门控机制,能有效捕捉时间序列中的长期依赖关系)在模式识别和非线性映射方面表现出色,有望作为物理模型的替代或补充,用于快速预测复杂系统的响应^[15-16]。通过历史观测数据或高精度数值模型结果进行训练,机器学习模型能够以几乎即时的速度给出预测结果:一方面,深度学习模型离线训练完成后,在线预测阶段计算速度极快,适合实时模拟需求;另一方面,深度学习可从数据中自动提取降雨与积水响应间复杂的非线性关系,有潜力提高预测精度。将数据驱动方法与物理模型相结合,既能保证一定的模拟准确性,又大幅提升计算效率,已成为智慧水务

领域的研究热点^[17],如梁汝豪等^[18]基于SWMM和机器学习方法对城市内涝进行了协同模拟,实现了物理精度与计算效率的兼顾;陈泽明等^[19]从算法分类、数据处理、模型训练与评估等多个角度系统梳理了城市内涝机器学习模拟的发展脉络,提出应融合物理约束和多源数据以提升模型泛化能力。因此,研究基于机器学习的平原城市内涝快速模拟方法,不仅在理论上丰富了洪涝模拟技术手段,在实践上也可作为城市防洪排涝部门提供高效决策支撑。

基于上述背景,本文以常熟市为研究对象,聚焦平原城市圩区内涝积水的快速模拟问题。常熟市具有代表性的平原水网特征和典型的内涝问题,选择该区域开展研究具有示范意义。本研究采用物理模型与数据驱动模型相结合的技术路线:首先利用InfoWorks ICM二维洪涝模型对不同降雨情景下的城市积水过程进行精细模拟,获取大量高分辨率的积水分布数据;然后以这些模拟结果为样本,训练深度学习模型,使其学会从降雨条件直接预测城市积水分布;最后通过对比试验验证深度学习模型的预测精度和效率,并分析其适用性。结果表明,该方法具有良好的精度与显著的效率优势,可为城市内涝快速预警和风险评估提供有效手段。下文详细介绍研究区域与数据、模型方法、结果与分析等内容。

1 研究方法

1.1 研究区域与洪涝机理模型构建

本文研究区域为江苏省常熟市主城区,地处长江下游南岸的冲积平原,属太湖流域水系。常熟市区地势低平,平均高程约4 m,市区外围由防洪堤和水闸围成圩区(俗称“大包围”),暴雨来临时需通过泵站提排雨水。城市建成区河网密布但天然比降很小,强降雨时易出现排水不及的内涝现象,见图1。

本研究收集了常熟市排水管网、地形高程(数字高程模型)、土地利用以及历次暴雨过程等资料,采用InfoWorks ICM软件建立城市雨洪一体化模型。模型包括地表二维汇流、管网与河道一维流和雨量径流模块耦合,对城市下垫面产汇流、管渠输水和地表积水进行模拟,见图2。

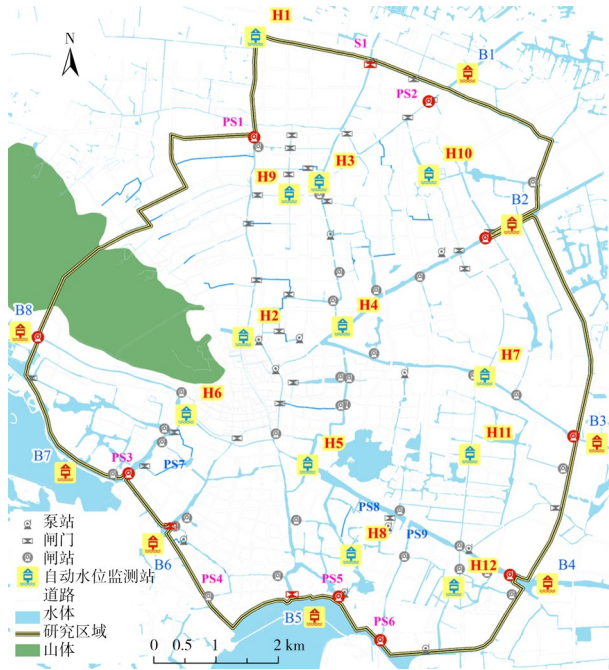


图 1 常熟市水网与水系工程分布

Fig. 1 Hydraulic network and engineering distribution of Changshu City

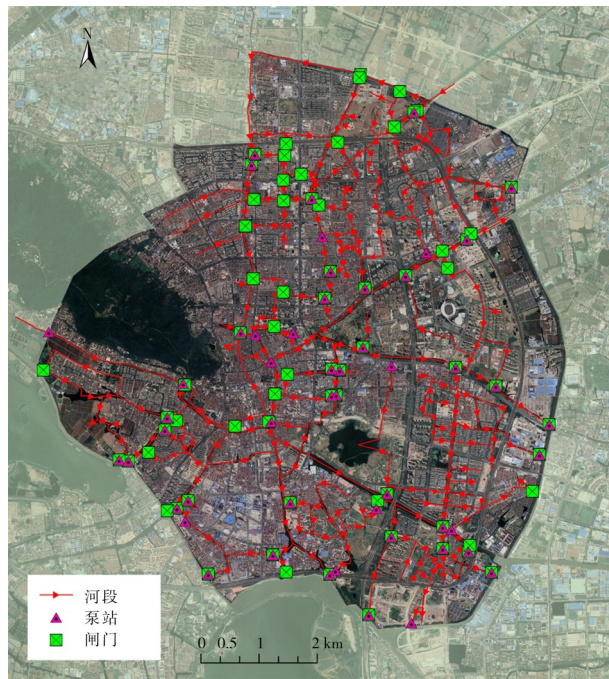


图 2 常熟市河网水动力模型结构

Fig. 2 Hydrodynamic structure of river network model in Changshu City

选取若干典型暴雨内涝事件对模型参数进行率定,使模型计算的积水范围和水深与实测或历史

记录相符,然后利用验证事件检验模型的精度。经校核,所构建的机理模型可以较为准确地再现研究区域的积水过程,模拟结果可作为后续机器学习模型训练的“真实值”基准。

1.2 机理模型率定验证

本文选取了 3 场具有代表性的降雨过程(2021 年台风暴雨、2016 年梅雨、2017 年短历时强降雨),对模型的模拟性能进行了系统评估,率定验证见表 1。通过比较 B1—B8(图 1)各水文断面处的模拟与实测水位峰值及拟合优度 R^2 ,发现模型在不同雨型下均表现出较强的适应能力与可靠性。

a) 台风暴雨场景(2021-07-24)。该场次作为模型参数率定的主要依据,降雨强度大、历时长,对模型的水动力模拟精度提出较高要求。

①峰值误差表现:所有站点模拟峰值与实测值误差控制在 ± 0.1 m 以内,其中 B1、B2、B3、B5 等误差小于 0.07 m,最大误差不超过 0.1 m,符合工程级精度要求。

②拟合优度 R^2 分析:所有站点 R^2 均在 0.96~0.97 区间,表明模拟曲线与实测水位具有极高的一致性,尤其 B5、B6、B7 等骨干河道断面,洪峰过程、陡涨陡落阶段均拟合良好。

③综合评估:说明模型结构合理,产汇流与水动力计算模块在极端强降雨下响应准确,适合作为未来台风暴雨预报的支撑工具。

b) 长历时梅雨过程(2016-07-01)。该场次特征为雨量持续、强度适中,过程水位变化相对平缓,主要考察模型的稳定性与积水响应滞后模拟能力。

①峰值误差表现:8 个站点中有 6 个站点误差控制在 ± 0.07 m, B5 站略高但不超过 ± 0.1 m,表现出良好一致性。

② R^2 分布特点:所有断面 R^2 集中在 0.94~0.96,其中 B1、B2、B5 拟合度最高,说明模型在平缓水位变化下具备稳定追踪能力。

③典型站点评估: B1(小支流)与 B4(干流汇合点)水位变化趋势清晰,模拟曲线几乎贴合实测曲线,反映模型对支流-干流响应关系刻画准确; B7、B8 两处下游站点表现良好,说明汇流与下泄动态平衡控制合理。

④综合评估:在典型梅雨天气下,模型展现出良好的中低强度降雨适应性,为防汛调度提供可信参考。

c) 短历时局地强降雨过程(2017-09-23)。该

工况降雨强度集中、历时短、水位快速波动,对模型在“快速响应能力”方面提出挑战。①峰值误差表现:所有站点误差均小于0.1 m, B1、B2等支流站点误差略大但仍处于工程容许范围内,最大误差为0.12 m。② R^2 变化规律: R^2 介于0.91~0.95,虽略低于其他工况,但依然表明模型具备较强的趋势预测能力。③特殊站点观察: B4(干流中游) R^2 为0.94,峰值误差控制在0.13 m以内,洪峰时间略有提前,说明在强降雨过程下,模型对产汇流时滞响应略有误差; B5、B6等站点在水位快速回落阶段的模拟仍然准确,说明退水过程模拟合理。④综合评估:尽管突发暴雨下模拟精度略有下降,但模型依然有效地捕捉水位突涨突落过程,具备实际预警可用性。

综上所述,模型参数率定与验证的结果令人满意。3场典型降雨工况下8个边界水位站的模拟水位峰值误差均在 ± 0.1 m左右,所有站点的决定系数均在0.90以上(表1、2),达到或超过常规水文模型精度评价的“良好”标准。这意味着所构建的水文-水动力耦合模型能够同时再现洪水过程的峰值和过程趋势,具有较高的模拟精度和鲁棒性。在率定工况中获得高精度拟合的参数同样适用于不同降雨情景,模型对长历时、中等强度降雨及短历时、高强度降雨均表现出良好的泛化能力。由此可见,本文率定的参数集合理且有效,验证了模型在研究区域内的适用性。经过率定与验证,本模型可用于后续城市内涝情景的模拟和风险评估,对研究区排水防洪规划提供可靠的技术支撑。

1.3 数据集构建与预处理

基于经过验证的物理模型,本文设计并模拟了多种暴雨情景以生成代理模型所需的数据样本。降雨情景包括常熟市历史典型暴雨过程以及不同重现期的设计暴雨过程,涵盖总雨量约70 mm(小雨)、170 mm(中等暴雨)、330 mm(特大暴雨)等不同强度和历时组合,共获得12场降雨下的城市积水响应数据用于模型训练,见图3以及表3,另有3场用于独立验证。从每场模拟中提取2个方面的数据:①若干城市易涝点的水深随时间变化序列;②整个城市范围内各时刻的积水深度空间分布。为便于

表1 率定验证

Tab. 1 Calibration validation

降雨日期	站点	实测峰值 /m	模拟峰值 /m	R^2
2016-07-01	B1	4.70	4.63	0.96
2016-07-01	B2	4.95	4.88	0.96
2016-07-01	B3	4.94	4.87	0.95
2016-07-01	B4	5.04	4.97	0.95
2016-07-01	B5	5.08	5.11	0.96
2016-07-01	B6	5.22	5.17	0.95
2016-07-01	B7	5.28	5.32	0.94
2016-07-01	B8	5.41	5.33	0.95
2017-09-23	B1	4.73	4.63	0.95
2017-09-23	B2	4.95	4.75	0.94
2017-09-23	B3	4.94	4.83	0.94
2017-09-23	B4	5.06	4.93	0.94
2017-09-23	B5	5.18	5.07	0.93
2017-09-23	B6	5.27	5.17	0.92
2017-09-23	B7	5.28	5.17	0.91
2017-09-23	B8	5.45	5.37	0.92
2021-07-24	B1	4.71	4.64	0.97
2021-07-24	B2	4.77	4.75	0.97
2021-07-24	B3	4.99	4.91	0.96
2021-07-24	B4	5.09	4.94	0.96
2021-07-24	B5	5.24	5.08	0.97
2021-07-24	B6	5.42	5.27	0.96
2021-07-24	B7	5.48	5.28	0.96
2021-07-24	B8	5.41	5.36	0.96

表2 率定验证结果统计

Tab. 2 Calibration verification result statistics

工况	特点	峰值误差 (绝对值)/m	R^2	适应性评价
2021台风暴雨	高强度、长历时	<0.10	0.96~0.97	非常优秀 (率定工况)
2016梅雨	中强度、长历时	<0.10	0.94~0.96	稳定良好
2017局地暴雨	高强度、短历时	<0.12	0.91~0.95	快速响应 准确

机器学习处理,对数据进行了预处理:雨量时间序列经过统一时间步长离散,并转换为二维图像形式;积水深度场离散到规则网格上表示,并进行归

一化处理。同时,引入网格坐标等区域编码信息作为输入特征之一,以帮助 CNN 模型识别不同区域的地势和排水特性差异。

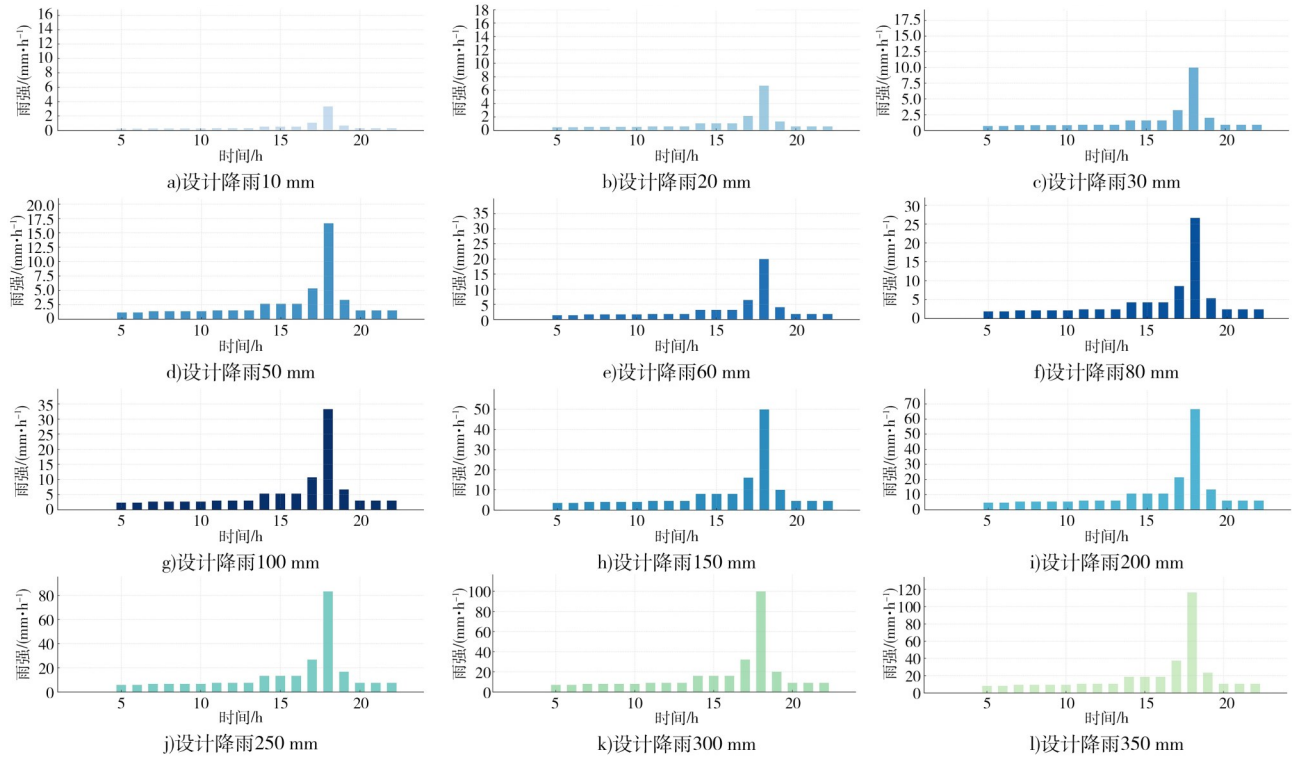


图 3 12场设计降雨柱状图

Fig. 3 Bar chart of twelve design rainfall scenarios

表 3 12场设计降雨

Tab. 3 Twelve design rainfalls

时段/h	雨量/%	积水/mm											
		10	20	30	50	60	80	100	150	200	250	300	350
1	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0
5	2.3	0.23	0.46	0.69	1.15	1.38	1.84	2.30	3.45	4.60	5.75	6.90	8.05
6	2.3	0.23	0.46	0.69	1.15	1.38	1.84	2.30	3.45	4.60	5.75	6.90	8.05
7	2.7	0.27	0.54	0.81	1.35	1.62	2.16	2.70	4.05	5.40	6.75	8.10	9.45
8	2.7	0.27	0.54	0.81	1.35	1.62	2.16	2.70	4.05	5.40	6.75	8.10	9.45
9	2.7	0.27	0.54	0.81	1.35	1.62	2.16	2.70	4.05	5.40	6.75	8.10	9.45
10	2.7	0.27	0.54	0.81	1.35	1.62	2.16	2.70	4.05	5.40	6.75	8.10	9.45
11	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50

(续表3)

时段/h	雨量/%	积水/mm											
		10	20	30	50	60	80	100	150	200	250	300	350
12	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50
13	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50
14	5.3	0.53	1.06	1.59	2.65	3.18	4.24	5.30	7.95	10.60	13.25	15.90	18.55
15	5.3	0.53	1.06	1.59	2.65	3.18	4.24	5.30	7.95	10.60	13.25	15.90	18.55
16	5.3	0.53	1.06	1.59	2.65	3.18	4.24	5.30	7.95	10.60	13.25	15.90	18.55
17	10.7	1.07	2.14	3.21	5.35	6.42	8.56	10.70	16.05	21.40	26.75	32.10	37.45
18	33.3	3.33	6.66	9.99	16.65	19.98	26.64	33.30	49.95	66.60	83.25	99.90	116.55
19	6.7	0.67	1.34	2.01	3.35	4.02	5.36	6.70	10.05	13.40	16.75	20.10	23.45
20	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50
21	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50
22	3.0	0.30	0.60	0.90	1.50	1.80	2.40	3.00	4.50	6.00	7.50	9.00	10.50
23	0	0	0	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	0	0	0

注:表头中的“10、20……350”表示单日设计降雨,mm。

1.4 LSTM时间序列预测模型

LSTM是一种适用于处理时间序列数据的循环神经网络。LSTM通过引入门控机制(输入门、遗忘门、输出门)解决传统RNN模型在长序列中存在的梯度消失与记忆衰减问题,适用于积水点水深的时序建模,见图4。本研究构建的LSTM模型以逐时刻的降雨强度序列作为输入,输出对应的目标积水点水深序列。

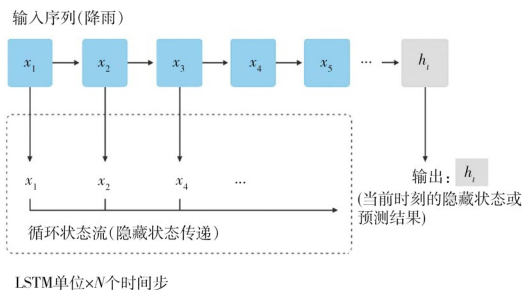


图4 LSTM模型结构

Fig. 4 LSTM model structure

LSTM网络单元核心计算过程见式(1)~(4)。

$$\text{遗忘门: } f_t = \sigma(W_f \cdot [h_{t-1}, \mathbf{x}_t] + b_f) \quad (1)$$

$$\text{输入门: } i_t = \sigma(W_i \cdot [h_{t-1}, \mathbf{x}_t] + b_i),$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, \mathbf{x}_t] + b_c) \quad (2)$$

$$\text{单元状态更新: } C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3)$$

$$\text{输出门: } o_t = \sigma(W_o \cdot [h_{t-1}, \mathbf{x}_t] + b_o),$$

$$h_t = o_t * \tanh(C_t) \quad (4)$$

式中: \mathbf{x}_t 为输入特征向量(包括当前时刻降雨量、累积雨量、前几时刻水深); h_t 为输出; C_t 为单元记忆。

1.5 CNN空间分布预测模型

采用卷积神经网络CNN直接预测城市二维积水分布。模型将整个降雨过程映射为二维图像序列输入,由多层卷积、池化和上采样组成的编码-解码结构提取降雨时空特征,输出指定时刻全区域的网格水深值矩阵,见图5。可以将CNN理解为一个高维非线性映射函数,输入降雨过程信息 X ,输出对应的积水分布 Y :

$$Y = f_{\text{CNN}}(X; \theta) \quad (5)$$

式中: θ 为CNN模型的参数集合,包括卷积核权重和偏置等。为了让CNN既掌握总体雨势特征又关注局部易涝区差异,模型输入除了降雨灰度图外还包

含反映空间位置的坐标通道,这相当于对不同区域“打上标签”,提高模型区分地形与排水条件差异的能力。本文CNN网络采用两层卷积下采样编码+两层卷积上采样解码的对称架构:编码阶段先后使用 5×5 卷积核(16个通道)和 3×3 卷积核(32个通道)提取特征,每层卷积后接步长2的最大池化层进行降采样;解码阶段通过双线性上采样逐步恢复到原始分辨率,并在最终输出层采用 1×1 卷积映射到单通道的水深预测结果。隐藏层激活函数采用ReLU,引入非线性表示能力。这样的CNN结构能够高效提取降雨过程与空间响应的映射关系,实现端到端的“降雨图像到积水图像”预测。为了进一步提升模型对重点积水区的识别能力,有研究尝试引入注意力机制。Wang等^[20]提出了一个结合层次地形空间注意力和多尺度降雨嵌入(Multi-scale Rainfall Embedding)的CNN-based模型,目标是预测洪涝影像,通过三重方式强化空间特征提取和降雨信息融合,从而显著提升洪水区域的预测准确率。

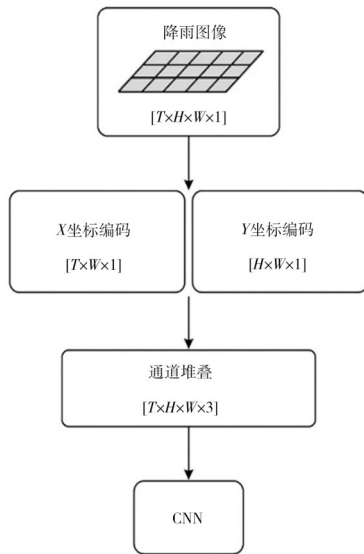


图5 CNN模型的多通道输入结构

Fig. 5 Multi-channel input structure of CNN model

1.6 模型训练与评价方法

采用前述12场样本的80%用于训练、20%用于验证,利用Python的TensorFlow/Keras深度学习框架对LSTM和CNN模型进行训练迭代。

损失函数:选用均方误差(Mean Squared Error, MSE)作为主要损失函数衡量模型输出与真实值的偏差,并通过反向传播迭代优化,其计算见式(6)。

$$E_{MS} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

式中: y_i 为真实值; \hat{y}_i 为模型预测值; N 为样本数(对于LSTM模型, N 为预测时刻数乘以输出位置数,对于CNN模型, N 为网格总像素数); E_{MS} 反映预测值偏离真实值的平均平方误差,数值越小表示精度越高。

训练过程中通过最小化MSE来优化模型参数,使代理模型尽可能逼近ICM模拟结果。值得一提的是,为提高CNN对积水范围的判断能力,模型训练中还尝试加入针对淹水/未淹水分类的二元交叉熵损失作为辅助,使模型在回归水深的同时更准确地预测淹水范围。优化算法方面,采用自适应学习率的Adam(Adaptive Moment Estimation)方法进行梯度下降迭代,初始学习率0.001,并结合提前停机策略避免过拟合。训练数据按8:2划分训练集和验证集,每轮迭代(epoch)在验证集上监控损失,如连续若干轮损失不降则降低学习率或停止训练。经过反复试验,LSTM模型在约100个epoch后收敛,CNN模型在150~200个epoch达到最佳,训练过程损失函数稳定收敛,表明模型成功学到了降雨与积水的映射关系。周添红等^[21]对城市内涝模拟中的数据驱动方法进行了系统评述,指出深度学习模型在降雨-响应关系建模方面具备优势,但在泛化能力与极端条件适应性方面仍需通过模型结构优化与样本扩充予以改善。

本文采用多种统计指标衡量模型预测精度。

a)均方根误差 E_{RMS} (Root Mean Squared Error, RMSE)。 E_{RMS} 是MSE的平方根,反映预测值与真实值偏差的平均幅度,见式(7):

$$E_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (7)$$

E_{RMS} 具有与原始数据相同的量纲,便于直接理解误差大小。本文计算了LSTM模型在各关键积水点处水深序列的RMSE,以及CNN模型在各时刻全域水

深分布的RMSE,然后取平均作为模型总体误差指标。RMSE越小表示模型预测越精确。

b) 纳什效率系数 E_{NS} (Nash-Sutcliffe Efficiency)。 E_{NS} 常用于评价模拟序列相对于观测序列的拟合优度,其定义为:

$$E_{NS} = 1 - \frac{\sum_{t=1}^N (O_t - P_t)^2}{\sum_{t=1}^N (O_t - \bar{O})^2} \quad (8)$$

式中: O_t 为第 t 时刻观测值(ICM模拟的真值); P_t 为模型预测值; \bar{O} 为观测序列平均值。 E_{NS} 取值范围为 $(-\infty, 1]$, 越接近 1 表示模型序列预测与真实序列吻合度越高; $E_{NS}=0$ 表示模型预测效果与平均值作为预测相当, E_{NS} 为负则表示不如直接用平均值预测。本文主要考察 LSTM 模型对关键积水点水深过程的 E_{NS} , 以及 CNN 模型对各网格点水深时序的 E_{NS} 分布情况。 E_{NS} 高于 0.8 通常表明模型对动态过程有较好再现能力。

此外,还对比了各模型的预测耗时。通过统计 LSTM 和 CNN 模型运行一次完整预测所需的计算时间,与物理模型模拟同一情景的时间进行对比评估,量化代理模型在计算效率上的优势。

2 结果与分析

2.1 模型预测精度评价

利用 3 场独立暴雨过程对训练好的代理模型进行检验,包括总雨量约 70 mm 的小雨、中等强度 (170 mm) 的暴雨和极端强降雨 (330 mm) 情景,具有代表性地覆盖了不同量级的降雨类型。图 6 给出了 LSTM 和 CNN 模型在各测试降雨下的总体误差统计,包含关键积水点水深预测的 E_{RMS} 和 E_{NS} 等指标。可以看出,对于中等和大型暴雨事件,2 种模型均取得较高的预测精度:LSTM 模型的水深预测平均 E_{RMS} 约 1.2~2.0 cm, E_{NS} 接近 0.95, 表明其在时间序列尺度上几乎与物理模型结果一致;CNN 模型的 E_{RMS} 略高但也仅在 1.0~3.0 cm 范围内,各时刻积水分布的平均 E_{NS} 亦达到 0.90 以上。图 7、表 4 展示了 2 个典型点位在 90 mm 降雨情景下的水深时序对比, LSTM 模型较好地捕捉了涝水上升—峰值—退水的变化趋势,水深峰值误差控制在 ± 5 cm 范围内,响应

时延误差小于 3 min,拟合趋势良好,证明 LSTM 成功捕捉到了累积降雨对后续积水的滞后影响。 E_{NS} 指标方面,大部分积水点序列的 E_{NS} 在 0.9 以上,说明代理模型对时间过程变化趋势具有很强的还原能力。




图 6 LSTM 和 CNN 模型在各测试降雨下的总体误差统计
Fig. 6 Overall error statistics of LSTM and CNN models under different test rainfall scenarios

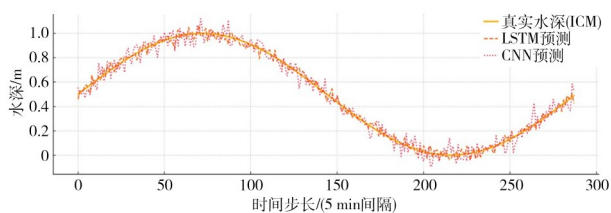


图 7 时间序列对比

Fig. 7 Comparison of time series

表 4 LSTM 模型时间序列预测精度评估

Tab. 4 Accuracy evaluation of time series prediction by

LSTM model

指标	点位 1	点位 2	平均
MSE	0.001 5	0.001 2	0.001 4
MAE/cm	2.90	3.20	3.05

CNN 模型则侧重对整个城市范围积水空间格局的预测。图 8—10 分别展示了代理模型对于小雨 (70 mm)、中等暴雨 (170 mm) 和特大暴雨 (330 mm) 3 个情景下峰值时刻城市积水分布的模拟结果,与机理模型的实际积水图进行对比。可以看出,CNN 模型在不同降雨强度下均能较好地预测主要积水区域的位置和范围。

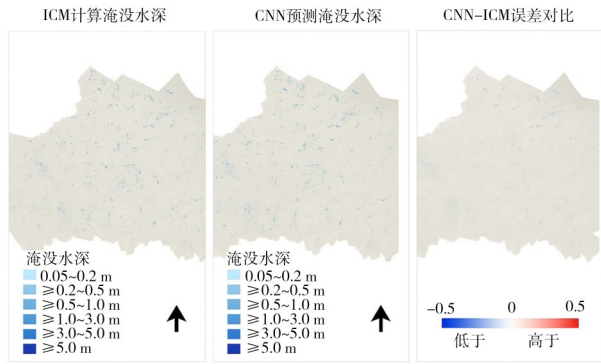


图 8 70 mm 降雨情景下对比

Fig. 8 Comparison under 70 mm rainfall scenario

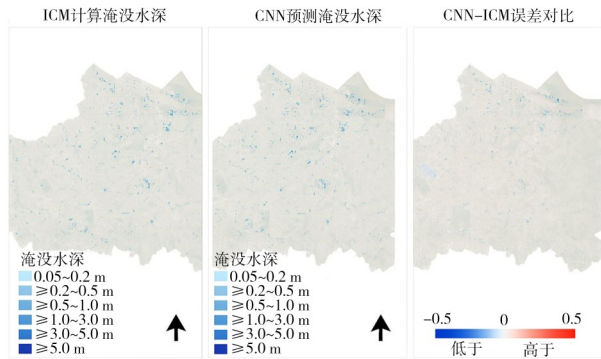


图 9 170 mm 降雨情景下对比

Fig. 9 Comparison under 170 mm rainfall scenario

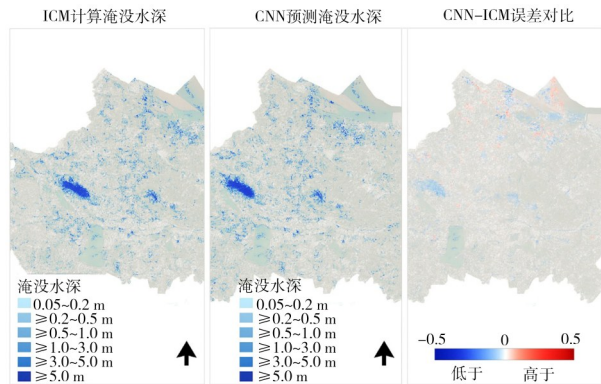


图 10 330 mm 降雨情景下对比

Fig. 10 Comparison under 330 mm rainfall scenario

对于 70 mm 的小雨情景(图 8),实际仅在局部低洼处产生了约 5 cm 的浅层积水,CNN 预测也成功识别出了该区域并给出接近的水深值,整体积水面积与真实情况吻合,只有对极个别极浅积水(小于 3 cm)的地点出现未能捕捉的情况。在 170 mm 暴雨下(图 9),城市西南侧形成了一片最大水深约 35 cm

的积水洼地,CNN 模型很好地重现了该大范围积水斑块,对中心区域水深的预测仅略低于真实值(约 30 cm)。对 330 mm 特大暴雨(图 10),物理模型模拟显示城市中西部大面积深积水(最大水深约 0.8 m),CNN 模型的预测几乎完全重现了深积水区域的形状和位置,最大水深预测值约 0.75 m,略低于真实值不到 0.1。综合各种强度情景,CNN 对积水范围的判断准确率较高,各场景的淹水范围交并比 IoU(Intersection over Union)均在 0.8 左右,说明大部分积水区域都被模型正确预测;水深值的平均误差在几厘米以内,主要积水区域水深的空间分布误差(预测值减真实值)大多在±(3~5)cm,仅在极少数深积水中心位置误差达到 5~8 cm。值得注意的是,CNN 模型对无样本参与训练的降雨情景仍表现出稳定的精度(表 5),这表明其具有一定的泛化能力,可以推广用于相似条件下的内涝模拟。

表 5 CNN 模型空间预测精度评估结果

Tab. 5 Evaluation results of spatial prediction accuracy of CNN model

指标	训练集	测试集
均方误差	0.002 1	0.002 8
平均水深误差/cm	3.6	4.3
淹没区域匹配率	0.91	0.87

可见,CNN 模型对积水深度空间格局的拟合精度较高,尤其在主积水区表现出良好的泛化能力。

2.2 计算效率与应用讨论

在确保预测精度的同时,代理模型最大的优势在于计算效率的提升。经过训练后的 LSTM 和 CNN 模型利用 GPU(Graphics Processing Unit)加速进行推理,对给定的降雨输入可在极短时间内生成积水预测结果。测试表明,对于持续 24 h 的暴雨过程(约 288 个 5 min 时步),LSTM 模型预测全程序列仅需约 0.05 s,CNN 模型输出整个城市峰值积水图也不到 1 s,而采用 InfoWorks ICM 模型模拟同一场景需耗时 30 min 以上。也就是说,机器学习代理模型的预测速度达到物理模型的 3 600 倍以上。这种近

乎实时的计算能力使得在预警响应中可以快速地评估不同降雨情景下的内涝风险。虽然训练深度学习模型本身需要一定时间(数分钟到数小时),但训练过程属于离线工作,可接受的离线训练换取在线瞬时预测,对于实际应用是非常有利的。

需要指出的是,代理模型的适用范围在于其训练数据的覆盖情景。当遇到超出训练样本分布的极端条件时(例如比330 mm更大的异常暴雨或排水措施发生重大变化),模型的外推能力将受到考验,可能出现误差增大或不稳定。因此,在实践中可通过不断补充丰富训练数据、引入物理约束等方式来提高模型的鲁棒性和可信度。此外,LSTM与CNN模型各有侧重:前者精于具体点位的过程模拟,后者擅长整体范围的快速评估,二者可结合用于不同尺度的预测需求。在实际预警中,可先利用CNN预估城市易涝分布范围,再对高风险点调用LSTM细致模拟水深演变,从而既掌握全局淹水态势又关注重点区域的积水变化。总的来看,本研究的机器学习代理模型为平原城市内涝预测提供了一种高效可行的技术路径,有望与传统物理模型形成互补,为城市防洪排涝决策提供支撑。未来还可进一步融合遥感与GIS等多源数据,增强预测结果的空间表达能力与可视化效果。例如,薛晓萌等^[22]基于遥感反演与地理信息融合方法,构建了城市内涝风险图,为模型结果落地应用提供了实践模板。

2.3 误差分析与模型改进探讨

尽管本文构建的LSTM与CNN模型在模拟精度与计算效率方面表现良好,但在降雨强度剧烈波动或地形结构复杂等情境下仍存在一定预测偏差。主要误差来源包括:①数据精度限制,训练样本基于InfoWorks ICM模拟结果,其准确性受DEM分辨率、管网数据完整性及降雨时空分辨率影响,易在复杂地形或排水设施信息缺失区域引入系统性偏差;②物理约束缺失,LSTM与CNN属于统计学习模型,缺乏显式物理机制表达,极端降雨或排水系统运行状态变化时预测稳定性下降;③空间结构刻画不足,现有模型对排水系统拓扑结构和地表空间异质性反映有限,导致局部区域识别误差;④样本

覆盖有限,降雨过程在峰值、持续时间和路径等形态特征上多样性不足,限制了模型的泛化能力。

针对上述问题,可从以下方面改进:①融合高分辨率地形、土地利用及多源降雨数据,提升训练样本代表性;②将浅水方程等物理约束引入网络结构或损失函数,增强模型在非典型工况下的适应性;③引入多尺度残差网络与注意力机制强化边界和深积水特征提取;④结合图神经网络刻画排水系统与地形耦合关系;⑤通过数据增强与不确定性建模提升模型对极端情景的稳健性。

3 结论

基于InfoWorks ICM构建的高精度城市洪涝机理模型为后续机器学习模型的训练提供了可靠的数据基础。以常熟市主城区为案例,通过实测资料率定与验证后的物理模型,能够较为准确地反映平原圩区内涝积水的形成与演化过程,为代理模型学习降雨与积水间复杂非线性关系提供了可信支撑。

LSTM在模拟关键积水点的水深时间序列方面表现出良好性能。模型有效捕捉了降雨引发积水的时滞性与累积效应,在多种强度降雨情形下均实现了接近物理模型的预测精度。多数积水点模拟的纳什效率系数超过0.9,预测的峰值水深及其出现时刻与参考值高度一致。

CNN可实现城市内涝积水空间分布的快速回归预测。在给定降雨条件下,模型可直接生成整城区积水深度分布图,对主要积水区域的识别具有较高准确性,淹水范围的交并比稳定在0.8左右。水深预测的平均误差控制在几厘米以内,表明其具备较强的空间模拟能力。

与传统的水文-水动力模型相比,基于深度学习的代理模型在运算效率方面具备明显优势。经训练后的LSTM和CNN模型可在秒级时间内完成模拟,相较ICM模型从数分钟至数小时不等的模拟耗时,整体提速可达百倍以上。这一特性为城市内涝的实时预警与快速响应提供了技术支撑。此外,模型在多个降雨情景中均表现出良好的泛化能力,适应性较强,具备进一步推广应用的潜力。

综上所述,本文提出的基于机器学习的内涝快速模拟方法在保障预测精度的同时显著提升了运算效率,为平原城市圩区的积水预报提供了实用可行的解决方案。未来研究可考虑进一步融合物理约束机制与实时观测数据,以提升模型在极端天气下的预测稳定性与适应性,为城市防洪排涝调度提供更强的数据支持能力。

参考文献:

- [1] 夏军,石卫. 变化环境下中国水安全问题研究与展望[J]. 水利学报, 2016, 47(3): 10-16.
XIA J, SHI W. Perspective on water security issue of changing environment in China [J]. Journal of Hydraulic Engineering, 2016, 47(3): 10-16. (in Chinese)
- [2] ZHOU Q Q, LENG G Y, SU J H, et al. Comparison of urbanization and climate change impacts on urban flood volumes: importance of urban planning and drainage adaptation [J]. Science of the Total Environment, 2019, 658: 24-33.
- [3] HALLEGATTE S, GREEN C, NICHOLLS R J, et al. Future flood losses in major coastal cities [J]. Nature Climate Change, 2013, 3: 802-806.
- [4] MAHMOUD S H, GAN T Y. Urbanization and climate change implications in flood risk management: developing an efficient decision support system for flood susceptibility mapping [J]. Science of the Total Environment, 2018, 636: 152-167.
- [5] ARNONE E, PUMO D, FRANCIPIANE A, et al. The role of urban growth, climate change, and their interplay in altering runoff extremes [J]. Hydrological Processes, 2018, 32(12): 1755-1770.
- [6] HUONG H T L, PATHIRANA A. Urbanization and climate change impacts on future urban flooding in Can Tho City, Vietnam [J]. Hydrology and Earth System Sciences Discussions, 2011, 8(6): 10781-10824.
- [7] 张启义. 北京房山区“7·21”特大暴雨灾害的成因及启示[J]. 中国防汛抗旱, 2023, 33(10): 43-47.
ZHANG Q Y. The cause and enlightenment of the “23·7” extremely rainstorm disaster in Fangshan District of Beijing City [J]. China Flood & Drought Management, 2023, 33(10): 43-47. (in Chinese)
- [8] 刘家宏,裴羽佳,梅超,等. 郑州“7·20”特大暴雨内涝成因及灾害防控[J]. 郑州大学学报(工学版), 2023, 44(2): 38-45.
LIU J H, PEI Y J, MEI C, et al. Waterlogging Cause and Disaster Prevention and Control of “7·20” Torrential Rain in Zhengzhou [J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(2): 38-45. (in Chinese)
- [9] 高俊峰,韩昌来. 太湖地区的圩及其对洪涝的影响[J]. 湖泊科学, 1999(2): 105-109.
GAO J F, HAN C L. Polders in Taihu Lake region and its effects on floods [J]. Journal of Lake Sciences, 1999(2): 105-109. (in Chinese)
- [10] 单玉书,蔡文婷,薛宣,等. 环太湖城市群防洪大包围建设影响及对策[J]. 中国防汛抗旱, 2018, 28(2): 56-59, 65.
SHAN Y S, CAI W T, XUE X, et al. The impacts and countermeasures of developing urban flood control systems around Taihu Lake [J]. China Flood & Drought Management, 2018, 28(2): 56-59, 65. (in Chinese)
- [11] 夏军,王惠筠,甘瑶瑶,等. 中国暴雨洪涝预报方法的研究进展[J]. 水利学报, 2022, 53(3): 284-295.
XIA J, WANG H Y, GAN Y Y, et al. Research progress in forecasting methods of rainstorm and flood disaster in China [J]. Journal of Hydraulic Engineering, 2022, 53(3): 284-295. (in Chinese)
- [12] WEI H B, WU H, ZHANG L Y, et al. Urban flooding simulation and flood risk assessment based on the InfoWorks ICM model: A case study of the urban inland rivers in Zhengzhou, China [J]. Water Science and Technology, 2024, 90(4): 1338-1358.
- [13] YIN W H, LIU J, FENG H T, et al. Study of flooding hazards in highly urbanized area based on a coupled one- and two-dimensional hydrological-hydrodynamic model [J]. Desalination and Water Treatment, 2025, 321. DOI: 10.1016/j.dwt.2024.100933.
- [14] GUO Z F, LEITÃO J P, SIMÕES N E, et al. Data-driven flood emulation: Speeding up urban flood predictions by deep convolutional neural networks [J]. Journal of Flood Risk Management, 2020, 14(1). DOI: 10.1111/jfr3.12684.
- [15] DANG T Q, LE T H, TRINH A D, et al. Application of machine learning-based surrogate models for urban flood depth modeling in Ho Chi Minh City, Vietnam [J]. Applied Soft Computing, 2024, 150. DOI: 10.1016/j.asoc.2023.111031.
- [16] BERKHAHN S, NEUWEILER I. Data driven real-time prediction of urban floods with spatial and temporal distribution [J]. Journal of Hydrology, 2023, 22. DOI: 10.1016/j.hydroa.2023.100167.
- [17] 刘媛媛,刘业森,郑敬伟,等. BP神经网络和数值模型相结合的城市内涝预测方法研究[J]. 水利学报, 2022, 53(3): 276-283.

- LIU Y Y, LIU Y S, ZHENG J W, et al. Intelligent rapid prediction method of urban flooding based on BP neural network and numerical simulation model [J]. *Journal of Hydraulic Engineering*, 2022, 53(3): 276–283. (in Chinese)
- [18] 梁汝豪, 兰甜, 林凯荣, 等. 基于SWMM的城市雨洪径流模拟研究: 以广州市猎德涌流域为例[J]. *人民珠江*, 2018, 39(6): 1–5, 15.
- LIANG R H, LAN T, LIN K R, et al. Simulation of urban rainfall–runoff based on SWMM: the case of Liede River Basin in Guangzhou [J]. *Pearl River*, 2018, 39(6): 1–5, 15. (in Chinese)
- [19] 陈泽明, 方序鸿, 李家叶, 等. 机器学习模型在城市内涝模拟预报中的应用综述[J]. *人民珠江*, 2025, 46(1): 9–22.
- CHEN Z M, FANG X H, LI J Y, et al. An overview of application of machine learning models in urban flood simulation and forecasting [J]. *Pearl River*, 2025, 46(1): 9–22. (in Chinese)
- [20] WANG F F, WANG Y, LI B, et al. Hierarchical terrain attention and multi-scale rainfall guidance for flood image prediction [C]//2023 IEEE International Conference on Image Processing (ICIP), Kuala Lumpur, Malaysia: 2370–2374.
- [21] 周添红, 唐佐槐, 褚俊英, 等. 极端暴雨条件下城市内涝模拟研究进展与展望[J]. *人民长江*, 2025, 56(5): 14–22, 30.
- ZHOU T H, TANG Z H, CHU J Y, et al. Progress and prospects of urban waterlogging simulation under extreme rainstorm conditions [J]. *Yangtze River*, 2025, 56(5): 14–22, 30. (in Chinese)
- [22] 薛晓萌, 李红舂, 黄晓霞, 等. 基于高分遥感的城市内涝数值仿真与风险评价研究[J]. *遥感技术与应用*, 2024, 39(4): 971–986.
- XUE X M, LI H G, HUANG X X, et al. Numerical simulation and risk evaluation of urban flooding based on high-resolution remote sensing [J]. *Remote Sensing Technology and Application*, 2024, 39(4): 971–986. (in Chinese)

A Rapid Inundation Simulation Method for Urban Waterlogging in Plain Polder Areas Based on Machine Learning

CHEN Houlin, WANG Jiahu*

(Hohai University, Nanjing 210024, China)

Abstract: Frequent short-duration and high-intensity rainstorms during the monsoon season have caused recurrent pluvial flooding and severe localized ponding in the central urban district of Changshu City, Jiangsu Province. For emergency response, purely physics-based hydrodynamic models are often too slow to provide actionable forecasts. This study aims to develop a rapid simulation approach that balances accuracy and computational efficiency by integrating physics-based modeling with deep learning, thereby enabling timely warnings, situational awareness, and decision support for urban flood risk management in a typical plain polder city. A 1D pipe-2D overland coupled hydrodynamic model was built in InfoWorks ICM for the representative polderized core of Changshu, explicitly representing stormwater pipes, inlets, pumps, gates, and surface flow pathways over high-resolution terrain. Twelve design rainstorms with different intensities and temporal patterns were simulated, and the resulting high-fidelity inundation depths were extracted as training and validation samples. Two complementary surrogates were designed: a long short-term memory (LSTM) network to forecast depth time series at critical nodes for operations, and a convolutional neural network (CNN) to regress full-domain flood-depth rasters for spatial situational awareness. Preprocessing ensured mesh-raster alignment and standardized rainfall and terrain inputs. Model skill was evaluated with metrics appropriate for temporal and spatial tasks, including coefficient of determination (R^2), Nash-Sutcliffe efficiency (NSE), mean absolute error (MAE), root-mean-square error (RMSE), peak-depth error, and map-based indicators such as intersection-over-union (IoU), precision, recall, and F1 score. Cross-scenario tests assessed generalization across rainfall intensities and hyetographs. The framework achieved high predictive accuracy while drastically reducing computation time. The LSTM reproduced hydrograph evolution at most monitored locations with $R^2 > 0.90$, capturing both rising and receding limbs. The CNN accurately reconstructed spatial inundation patterns governed by micro-topography and road embankments; peak-depth errors were controlled within ± 5 cm, and the IoU for inundation extent reached 0.87. Compared with the full InfoWorks ICM solver, the surrogate-based workflow delivered $\geq 100\times$ speed-up, enabling second- to minute-level inference on standard hardware. Error analysis shows

residuals concentrate near sharp elevation transitions and curbed road segments where mesh-raster misalignment is most influential. Including near-dry states and first-flush periods in training reduces false positives and improves depiction of wetting-drying fronts. A demonstration case indicates that the method provides actionable depth maps and node-level forecasts early in the event window, supporting emergency routing, temporary storage scheduling, and pump dispatch. Coupling deep learning surrogates with a calibrated 1D/2D hydrodynamic model substantially enhances the timeliness of urban flood prediction without sacrificing accuracy, meeting operational demands for rapid warning and decision support in polderized plain cities. The workflow is reproducible and transferable to similar low-relief urban regions, provided a baseline hydrodynamic model is available for scenario generation and that training covers multiple storm intensities and early wetting phases. Future work will focus on probabilistic outputs via ensemble surrogates, tighter data assimilation with real-time sensors, and streamlined deployment within municipal emergency platforms.

Keywords: urban waterlogging; flood simulation; machine learning; convolutional neural network; long short-term memory network

(责任编辑:向 飞)