

赵宇, 梁益银, 鹿鹏程, 等. 基于 STFS-Urban 的秀水河流域洪涝过程模拟[J]. 水利水电技术(中英文), 2025, 56(10): 31-45. DOI: 10.13928/j.cnki.wrahe.2025.10.003

ZHAO Yu, LIANG Yiyin, LU Pengcheng, et al. The flood process simulation of the Xiushui River Basin based on STFS-Urban[J]. Water Resources and Hydropower Engineering, 2025, 56(10): 31-45. DOI: 10.13928/j.cnki.wrahe.2025.10.003

基于 STFS-Urban 的秀水河流域洪涝过程模拟

赵宇^{1,2}, 梁益银^{1,2}, 鹿鹏程^{1,2}, 黄欣³, 张书亮^{1,2}

(1. 南京师范大学虚拟地理环境教育部重点实验室, 江苏南京 210023; 2. 江苏省地理信息资源开发与利用协同创新中心, 江苏南京 210023; 3. 沈阳市勘察测绘研究院有限公司, 辽宁沈阳 110004)

摘要:【目的】自然流域通常具有复杂的干支流体系, 短历时强降雨作用下, 产汇流过程加剧, 河道流量激增, 水位上涨, 易发生严重的洪涝灾害。为提高流域洪涝模拟的时效性与准确性, 【方法】基于洪涝时空模拟模型 STFS-Urban, 进行集成模式下的时空交互机制分析与特征参数表达, 进一步构建标准数据集, 结合改进的 Transformer 深度学习算法, 实现流域洪涝物理模型和深度学习模型的耦合集成。以沈阳市秀水河流域作为研究区域, 基于“2022-07-06”“2022-07-28”两场典型暴雨监测数据, 开展洪涝过程情景模拟, 将模拟结果与公主屯水文站实测数据进行验证分析。【结果】结果显示, 预测水位与实测水位差值均小于 0.5 m, 误差在 1.5% 以内; 预测峰现时间与实测时间误差均小于 1.85 h, 所构建的流域洪涝集成模型预测淹没范围、洪水演进趋势与实际情况相符, 模拟时效较物理模型提升约 31~34 倍。【结论】结果表明, 所建立的 STFS-Urban 流域洪涝集成模型, 能够较好地模拟洪水演进过程, 在保证精度的同时有效提升了计算效率, 能够为流域洪涝灾害的防治和对策制定提供科学依据。

关键词: STFS-Urban 模型; 流域洪涝模拟; 深度学习; Transformer; 秀水河; 降雨; 径流; 洪水演进

DOI: 10.13928/j.cnki.wrahe.2025.10.003

开放科学(资源服务)标志码(OSID):

中图分类号: P333.2

文献标志码: A

文章编号: 1000-0860(2025)10-0031-15



与作者互动
溯源·溯科班

The flood process simulation of the Xiushui River Basin based on STFS-Urban

ZHAO Yu^{1,2}, LIANG Yiyin^{1,2}, LU Pengcheng^{1,2}, HUANG Xin³, ZHANG Shuliang^{1,2}

(1. Key Laboratory of VGE of Ministry of Education, Nanjing Normal University, Nanjing 210023, Jiangsu, China;

2. Jiangsu Center for Collaborative Innovation in Geographical Information Resource Development and Application,

Nanjing 210023, Jiangsu, China; 3. Shenyang Geotechnical Investigation and Surveying

Research Institute Co., Ltd., Shenyang 110004, Liaoning, China)

Abstract: [Objective] Natural catchments typically have complex tributary systems. Under the influence of short-duration, intense rainfall, the process of runoff generation and concentration is intensified, leading to a surge in river discharge and rising

收稿日期: 2024-10-25; 修回日期: 2024-12-10; 录用日期: 2024-12-12; 网络出版日期: 2025-01-21

基金项目: 国家自然科学基金项目(42271483); 江苏省自然资源科技项目(JSZRKJ202405)

作者简介: 赵宇(2000—), 男, 硕士研究生, 主要从事洪涝智能建模与模拟研究。E-mail: zhaoyu_gis@163.com

通信作者: 张书亮(1974—), 男, 教授, 博士, 主要从事洪涝智能建模与模拟研究。E-mail: zhangshuliang@njnu.edu.cn

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

water levels, which increases the likelihood of severe flooding. To improve the timeliness and accuracy of basin flood simulations, [Methods]the spatiotemporal flood simulation model STFS-Urban is used to analyze the spatiotemporal interaction mechanisms and characteristic parameter expressions under the integrated model. A standard dataset is constructed, and the coupling integration of the basin flood physical model with the improved Transformer deep learning algorithm is achieved. The Xiushui River Basin in Shenyang is selected as the study area, where flood process scenario simulations are conducted using monitoring data from two typical heavy rainfall events on “2022-07-06” and “2022-07-28.” The simulation result are validated through comparison with observed data from the Gongzhutun hydrological station. [Results]The results show that the difference between the predicted and observed water levels is less than 0.5 m, with an error within 1.5%. The error in the predicted peak time relative to the observed time is less than 1.85 hours. The constructed integrated basin flood model accurately predicts the inundation extent and flood evolution trends, which are consistent with the actual situation. The simulation efficiency is approximately 31 to 34 times higher than that of the physical model. [Conclusion]The results indicate that the established STFS-Urban basin flood integrated model is capable of effectively simulating the flood evolution process. While ensuring accuracy, the model significantly enhances computational efficiency and can provide a scientific basis for the prevention and control of river basin flood disasters and the formulation of countermeasures.

Keywords: STFS-Urban Model; basin flood simulation; deep learning; Transformer; Xiushui River; rainfall; runoff; flood routing

0 引言

受所处地理位置、特有地形条件及季风气候的影响,我国降雨时空分布不均,大部分地区遭受不同程度的洪涝灾害,造成的社会经济损失与日俱增^[1]。根据《中国水旱灾害防御公报 2023》数据显示,2023 年全国平均降水量为 600 mm,较常年偏少 4%,由于气候极端反常,部分地区暴洪极涝、情势偏重,海河流域发生流域性特大洪水、松花江流域部分支流发生超历史实测记录洪水^[2]。洪涝灾害导致全国 527 893 万人次受灾,直接经济损失达 2 445.75 亿元。洪涝模拟作为洪涝灾害治理中的典型“非工程性”数字技术,在灾情监测、风险识别、预报预警中发挥着重要作用^[3-4],已成为业界和多学科研究关注的热点领域。

当前,流域洪涝模拟研究主要采用“知识驱动”与“数据驱动”两种方式^[3-5]。以水文水动力学原理和洪涝物理模型为基础的知识驱动模拟方式,可通过过程机理表达、地理计算等物理建模方法,揭示洪涝地理现象的空间分布、时空过程和演变规律^[6-8]。周紫蕊等^[9]基于 InfoWorks ICM 模型建立城市水文模型与一维河网水动力耦合模型,并开展洪涝模拟的有效性验证,证明水文水动力模型能够较好地模拟流域降雨产汇流特性,可用于流域精准、数字化防洪调度;黄国如等^[10]通过构建 InfoWorks ICM 洪涝仿真模型,对广州东濠涌流域进行多重再现期暴雨情景模拟与洪涝灾害风险评估,所绘制流域风险区划图能较好地反映流域的风险分布,为防洪排涝重点关注区域提供参

考;赵天逸等^[11]基于 CAESAR-LisFlood 模型进行英国塞文河流域长时空维度上的演化预测与数值模拟,创新性地提出能够使防洪措施更精确可控的设置,为洪涝治理规划方案的比选提供新思路。随着自然水循环规律和水文水动力物理机制的不断完善,基于洪涝模型的知识驱动方式已逐渐成为目前开展洪涝模拟研究的主流方法^[5,12]。但此类方法重视地理过程机理描述,对数据的时空分辨率要求严格^[13],在面向地理、气象和水文观测等多模态大数据时,模型与观测大数据难以有机结合。

针对洪涝模拟的计算效率和实时性需求^[14-15],以深度学习技术为代表的驱动方式被越来越多地应用在流域洪涝相关工作。YANG 等^[16]以淮河流域为研究区,从致灾因素、灾害环境、承灾主体、防灾减灾四个方面进行研究,利用长短期记忆网络成功预测了该区域洪涝风险;李云良等^[17]考虑鄱阳湖湖泊流域多因素的共同作用,采用典型 BPNN 神经网络模型进行鄱阳湖水位快速模拟,综合分析鄱阳湖水位与其主控因子之间的响应关系;SHU 等^[18]探讨了卷积神经网络(CNN)在预测河流流量方面的适用性,并将其性能与人工神经网络和极限学习机进行了比较,结果表明 CNN 相对于浅层神经网络架构具有更加优越的性能。数据驱动方法利用水文气象等观测大数据进行时间序列的数学分析,学习给定样本后即可建立输入信息与输出信息的映射关系,极大提高了洪涝模拟的计算效率^[19-20],但此类方法忽略了洪涝过程的物理意义,对复杂下垫面等环境变化缺乏足够的适应性,存在着不确定性高、可解释性弱的局限^[21-23]。

近年来,部分学者尝试将“知识驱动”方法的精准度和“数据驱动”模型快速求解的优势相结合,突破单一驱动方式的瓶颈问题^[24],开展兼具物理基础和计算效率的流域洪涝时空模拟方法的研究^[25-28]。其中,STFS-Urban模型(Spatio-temporal flood simulation model for urban, STFS-Urban)采用“知识-数据”双驱动的洪涝模拟方式^[29],融合物理模型与深度学习优势,提取时空特征参数,通过构建具有强模仿能力的神经网络学习水文水动力模型的模拟过程,在洪涝规律挖掘、推理预测以及模拟计算的效率等方面具有独特优势。

本文以河网密集、洪涝易发的沈阳市秀水河流域为例,利用基础地理信息数据与水文监测数据,以GIS技术和深度学习技术为支撑,建立流域洪涝集成模型并模拟洪涝过程。探究流域洪涝物理模型和深度学习集成的洪涝模拟方法,以期推动知识驱动与数据驱动方法相互融合,实现洪涝高精度时空模拟,为流域洪涝灾害应急管理与防洪减灾提供技术支撑。

1 研究区域及数据

1.1 研究区概况

本文研究对象为沈阳市秀水河流域,秀水河是辽河干流水系的河流,发源于辽宁省康平县西南部,纵贯法库县西部地区,在新北市汇入辽河,全长约180 km,支流众多。研究区边界在参考官方水系图的基础上,结合地形图与流域遥感影像进行手动调整,总面积约为1 800 km²,具体情况如图1所示。

1.2 数据来源

流域洪涝建模与模拟所需的基础数据包括:河道断面数据、河床与河漫滩数字地形高程模型(digital elevation model, DEM)、土地利用类型数据、河岸堤坝资料、河流水文监测数据等多种类型数据。其描述和来源如表1所列。

表1 秀水河流域洪涝模型建模数据

Table 1 Basin flood model data of Xiushui River

数据类型	数据描述	数据来源	数据格式	时空分辨率
数字高程(DEM)	流域地表与水下地形高程	国家地球系统科学数据中心	栅格文件	30 m×30 m
土地利用类型	地表与河床土地利用类型	国家地球系统科学数据中心	栅格文件	30 m×30 m
河道断面形状	河道断面形态特征	基于地形高程提取	CAD文件	—
河流水系	秀水河流域水系分布情况	由天地图影像提取	.shp文件	—
流域边界	秀水河流域边界范围	由DEM及河流水系提取	.shp文件	—
河岸堤坝资料	包含堤高、堤宽等基本信息	秀水河堤坝设计规划	.shp文件	—
雨水情数据	11个气象站历史降雨监测时序	沈阳市水务局	Excel文件	1 h
河流水文监测数据	水文站历史水位监测时序	沈阳市水务局	Excel文件	1 min

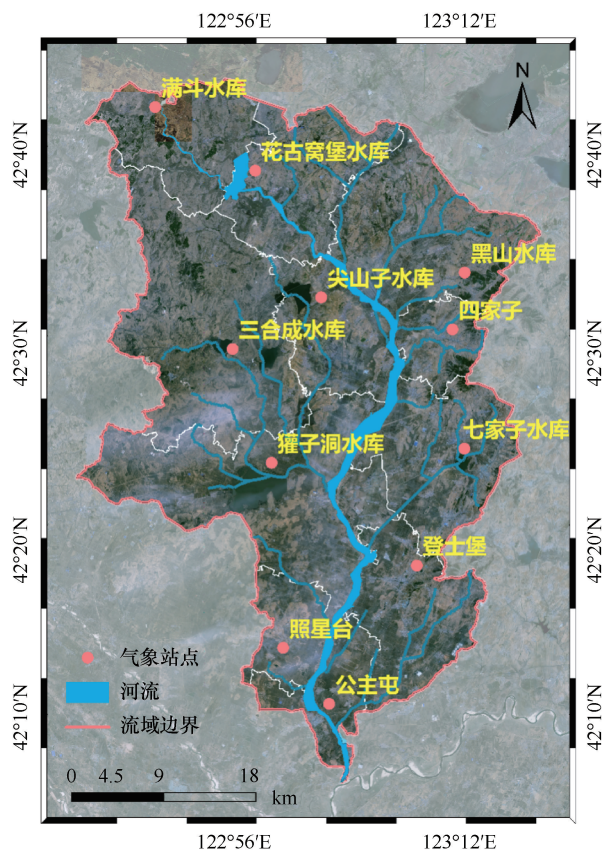


图1 秀水河流域示意

Fig. 1 Schematic diagram of the Xiushui River basin

1.3 STFS-Urban模型

STFS-Urban是基于“知识-数据”双驱动的城市新型分布式洪涝模型,包含多尺度降雨反演、多结构地理建模与多情景时空模拟等模块,具有河道、地表、堤坝、管网等多要素精细化耦合建模功能,具备城市强降雨与江河洪水引发的城市外洪内涝情景动态模拟能力,可满足“流域-城市”洪涝过程的多样化数值模拟要求。

对于流域洪涝过程模拟,STFS-Urban基于二维浅水动量方程与连续性方程,采用均匀栅格水文计算单元来模拟雨水受重力作用在地表的流动过程,其

表达式为

$$\frac{dh_{i,j}}{dt} = \frac{Q_{x_{i-1,j}} - Q_{x_{i,j}} + Q_{y_{i,j-1}} - Q_{y_{i,j}}}{\Delta x \Delta y} \quad (1)$$

$$Q_{x_{i,j}} = \frac{h_{flow}^{5/3}}{n} \left(\frac{h_{i-1,j} - h_{i,j}}{\Delta x} \right)^{1/2} \Delta y \quad (2)$$

式中, $h_{i,j}$ 为 (i, j) 网格处的水面高度; Δx 和 Δy 为网格大小; Q_x 、 Q_y 为网格间 x 方向和 y 方向上的流量; n 为曼宁糙率系数, 可以根据地表土地覆盖类型推算其参数值; h_{flow} 为栅格水深。

利用隐格式的有限差分法对上述浅水方程进行求解, 可以计算出相邻的栅格单元间的水流方向和水流交换量, 在不断地迭代过程中根据四个方向上的流量更新栅格单元的水深和水位。

2 流域洪涝集成模型构建

模型集成是指将多个不同的模型进行组合, 以提升预测准确性、鲁棒性和泛化能力的技术方法。通过综合不同模型的优势, 集成模型能够更有效地处理复杂问题, 减少单一模型可能出现的偏差和不足。本研究基于 STFS-Urban 多结构地理建模模块构建流域洪涝物理模型, 利用其模拟结果构造流域洪涝序列时空数据集; 结合数据集时空特征, 设计基于自注意力机制的 Transformer 神经网络结构, 进行模型训练与超参数优化, 最终实现流域洪涝物理模型和深度学习模

型的深度集成, 完成流域洪涝集成模型的构建。建模流程如图 2 所示。

2.1 流域洪涝物理模型构建与率定

(1) 构建流域陆表水底一体化地形。由于单一数字地形高程模型受制于采集方法无法对河底地形进行描述^[30], 本研究结合高精度水下地形测量结果与河道断面形状对 DEM 进行修正, 实现水下三维地形与流域 DEM 数据的镶嵌与融合, 修正后的 DEM 能够更为精确地刻画河床与河漫滩的形态。

(2) 构建流域河网水文模型。基于 ArcGIS 软件对秀水河干流及支流的河道中心线折点进行概化提取, 最终根据 31 条河道中心线共提取折点 6 638 个。将河道点数据导入 STFS-Urban, 通过标识符建立干支流交汇关系, 基于河道与河漫滩土地利用类型, 生成地表曼宁格网^[31], 取河道曼宁系数为 0.03, 完善河名、河宽等相关信息, 构建流域河网模型。

(3) 构建河岸堤坝模型。STFS-Urban 通过位置、堤高、堤宽与走向等参数描述河道两侧堤坝形态, 根据秀水河两岸堤坝观测信息进行相关参数的设定, 完成河岸堤坝模型的构建。

(4) 确定模型边界条件与初始条件。确定模型上、下游边界条件分别为花古窝堡水库与公主屯水文站的实测水位变化过程。因秀水河流域上下游落差较大, 故采用初始水深作为模型初始条件。暴雨

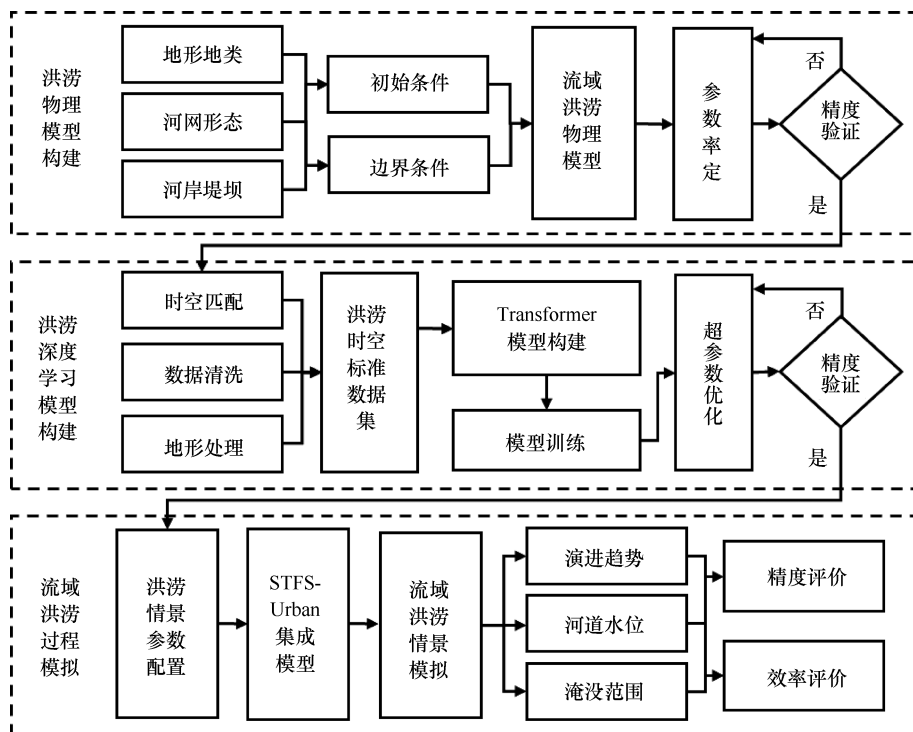


图 2 流域洪涝集成模型建模流程

Fig. 2 Modeling process of the basin flood integrated model

发生前, 河道尚未溢流, 根据水文站历史观测记录, 设定河道初始水深为 0.5 m, 河道外初始水深为 0。

流域洪涝物理模型运行时需要部分经验参数, 主要包括: 地表透水/不透水区曼宁系数、入渗率、渗透衰减系数、干燥时间等, 这些参数通常只与模拟区域的下垫面物理特性有关, 不受降雨情景的变化而变化^[32]。此部分参数需根据模型给出的理论参考范围和模拟情景进行率定, 适用于不同降雨情景下的洪涝过程模拟。

由于秀水河流域面积较大, 降雨呈现空间异质性^[33-34], 即区域内不同位置所经历的降雨雨强、历时均不同, 因此基于流域范围内气象站点雨水情监测数据进行空间插值, 构建多尺度降雨时空网格作为物理模型降雨输入。将 2019-08-03、2019-07-29、2020-08-24、2021-06-15、2021-07-30 等 5 场洪水场次作为流域洪涝物理模型率定场次, 取最小计算时间步长为 0.000 5 h, 模拟结果以 30 min 为时间步长进行输出。基于公主屯水文站河流水文监测数据, 选取洪涝过程中水文站监测点处水位的峰值误差 (Probable Error, PE) 与纳什效率系数 (Nash-Sutcliffe efficiency coefficient, NSE) 作为检验模型精度的标准。参数率定目标为河流水位的模拟值变化趋势与观测值基本吻合, 峰值误差小于 20%。

峰值误差 PE

$$PE = \frac{D_{sim} - D_{obs}}{D_{obs}} \quad (3)$$

纳什效率系数 NSE

$$NSE = 1 - \frac{\sum_{t=1}^T (Q_0^t - Q_s^t)^2}{\sum_{t=1}^T (Q_0^t - \bar{Q}_0)^2} \quad (4)$$

式中, D_{sim} 为水位的模拟峰值; D_{obs} 为水位的观测峰值; Q_0^t 为 t 时刻的观测值; Q_s^t 为 t 时刻的模拟值; \bar{Q}_0 为观测值的平均值。

由于模型直接输出结果为栅格水深值, 参数率定时需进一步与数字地形高程叠加求得水位。参数率定结果如表 2 所列。

2.2 流域洪涝标准数据集构建

率定后流域洪涝物理模型模拟得到的结果可视为包含了水循环机理的模型知识, 为构建 STFS-Urban 流域洪涝集成模型的标准数据集, 需进一步结合相关地理数据, 进行模型参数的时空匹配, 完成数据的清洗和筛选。

表 2 流域洪涝物理模型参数率定结果

Table 2 Calibration results of the basin flood model parameters

序号	待率定参数	物理意义	率定结果
1	N_{Imperv}	不透水区曼宁糙率系数/ $m^{1/3} \cdot s^{-1}$	0.017
2	N_{perv}	透水区曼宁糙率系数/ $m^{1/3} \cdot s^{-1}$	0.032
3	$MaxRate$	最大入渗率/ $mm \cdot h^{-1}$	78.5
4	$MinRate$	最小入渗率/ $mm \cdot h^{-1}$	3.4
5	$Decay$	渗透衰减系数	3.13
6	$Drytime$	干燥时间/d	4.5

2.2.1 降雨和水深时空匹配

深度学习模型作为一种数据驱动模型, 在模拟过程中将降雨序列作为样本输入特征, 水深作为预测结果的样本输出标签, 数据特征表现为时序(或时刻)到时刻的变换。因此, 降雨和水深的数据结构共同决定了深度学习模型的网络结构及参数。通常为了简化计算, 洪涝物理模型中降雨和水深的输入和输出维度保持一致, 即拥有相同的时间步长; 而真实模拟中往往具有不同精度的数据条件和模拟需求。

为了使模型集成适用于不同的降雨和水深时间尺度, 需要确定物理模型和深度学习模型的时空特征参数交互机制, 让构建的集成模型具有更好的普适性。降雨和水深的时空特征交互示意机制如图 3 所示。降雨的总时长和时间步长由降雨序列的长度和时间差决定。基于基础的地表漫流模拟的时空特征参数, 模型间的时空特征交互机制参数定义如表 3 所列。

表 3 时长交互机制参数

Table 3 Duration interaction mechanism parameters

变量名	描述	单位
$step_R$	降雨时间步长	min
t_R	降雨事件时长	h
$step_D$	水深时间步长	min
t_D	洪涝模拟时长	h
t_{his_r}	历史降雨回溯时长	h




图 3 时间步长参数交互机制

Fig. 3 Time step parameter interaction mechanism

基于定义的变量, 降雨和水深时间步长的比值

k 为

$$k = \frac{step_R}{step_D} \quad (5)$$

此基础上, 模型进一步考虑降雨序列的历史特征。历史的降雨值在一定程度上直接反映了降雨雨型的局部特征, 是模型训练过程中的重要特征因子。而回溯的历史降雨数量影响了样本输入特征的维度, 因此时间参数的交互是影响集成模型结构的重要因素。降雨序列回溯的降雨值(或栅格)的数量为

$$num_{his_r} = \frac{t_{his_r}}{step_R} \quad (6)$$

由于本文所构建集成模型输入输出的时空特征维度存在差异, 因此采用基于集成机理表达的洪涝水深时空特征参数转化过程进行时空匹配, 具体流程如图 4 所示。

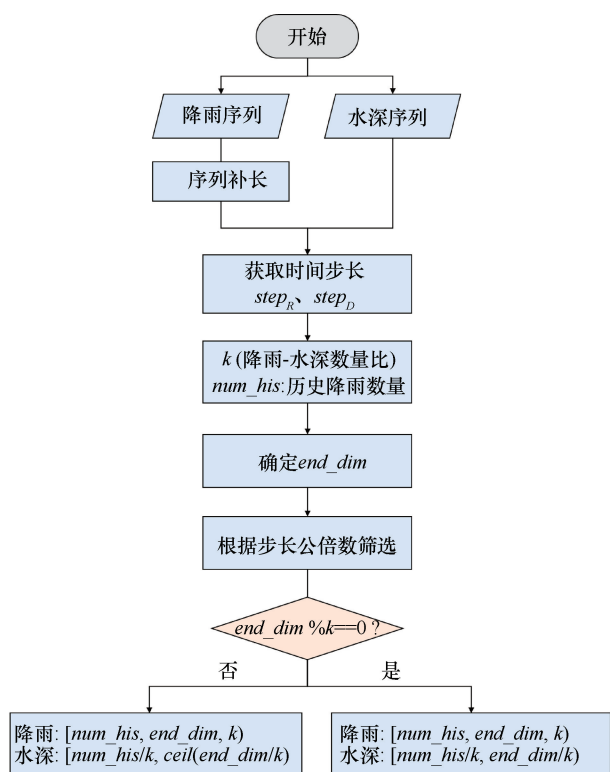


图 4 时间步长参数匹配流程

Fig. 4 Time step parameter matching process

降雨事件时长 t_R 具有随机性, 为使构造的数据集具有统一的时空特征, 需将降雨序列进行统一补长。基于集成建模设定的最大降雨时长, 将降雨序列按时间步长补长, 设置补长序列值为 0, 表示补长序列未发生降雨。因此考虑的最大维度为

$$dim_{end} = \min\left(\frac{t_R}{step_R} + num_{his_r}, \frac{t_{max}}{step_R}\right) \quad (7)$$

在此基础上, 从降雨输入和水深输出序列选择样本的间隔需满足降雨时间步长 $step_R$ 和水深时间步长 $step_D$ 的最小公倍数。匹配的过程等效于对洪涝水深数据的清洗和筛选, 从而将未匹配的降雨和水深数据进行过滤。

通过以上流程完成降雨和水深的时空匹配, 降雨序列步长为等长时间后, 基于降雨和水深的时间步长差异, 匹配相同时刻的降雨输入和水深输出, 为完成可供深度学习模型训练的标准数据集构造提供基础。

2.2.2 集成模型数据集构建

(1) 输入特征。在完成洪涝水深数据时空匹配的基础上, 进一步完成集成模型数据集的构建。构建的关键是对数据集的输入因子进行标准化定义。最终数据集的样本输入特征代表经过时空匹配的某一时刻水文气象因子集合, 表示为

$$X = \{x_i, 1 \leq i \leq m\} \quad (8)$$

$$x_i = \{t, r_i, r_i^{his}, g\} \quad (9)$$

式中, 每个样本输入包含的水文气象特征包括时间 t 、当前时刻的降雨强度 r_i 、指定回溯时长的历史降雨序列 r_i^{his} 及包含地理特征因子 g 。

假定洪涝过程的降雨事件为 R , 则 R 的维度特征为固定时间步长的一维时间序列, 表示为

$$R = \{r_0, r_1, r_2, \dots, r_m\} \quad (10)$$

而历史降雨序列在一定程度上直接反映了降雨雨型的局部特征, 且回溯的历史降雨时长影响了样本输入特征的维度, 表示为

$$R^{his} = \begin{Bmatrix} r_0^{his} \\ r_1^{his} \\ \dots \\ r_{m-n}^{his} \end{Bmatrix} = \begin{Bmatrix} r_n, r_{n-1}, r_{n-2}, \dots, r_1, r_0 \\ r_{n+1}, r_{n+1-1}, r_{n+1-2}, \dots, r_2, r_1 \\ \dots \\ r_m, r_{m-1}, r_{m-2}, \dots, r_{m-n+1}, r_{m-n} \end{Bmatrix} \quad (11)$$

地理特征因子基于区域的地形高程 dem 进行演算, 包括坡度、坡向等。对于这些地理因子的筛选需经过集成模型的训练与性能评估, 表示为

$$g = \{dem, slope, aspect\} \quad (12)$$

(2) 输出标签。相比于输入特征, 输出标签即为时空匹配后相同时刻的水深栅格, 表示为

$$Y = \{d_i, 1 \leq i \leq m\} \quad (13)$$

基于以上定义, 本文构造的集成模型数据集属性特征如表 4 所列。

由于构建后的数据集样本输入特征的数据维度和数值单位存在差异, 需要对模型数据集进行进一步数据增强处理, 以便于训练深度学习模型。

表4 洪涝时序数据集属性特征

Table 4 Attribute characteristics of the flood time series dataset

属性名称	变量编号	数据维度	数据类型	单位
时间	x_1	标量	时间戳	—
实时降雨	x_2	1D/2D	浮点型	mm/h
历史降雨	x_3	1D/2D	浮点型	mm/h
高程	x_4	2D	浮点型	m
坡度	x_5	2D	浮点型	°
坡向	x_6	2D	浮点型	°
水深	y	2D	浮点型	m

2.2.3 水深数据清洗

模拟得到的水深栅格存在部分较小值和不连续栅格“水坑”，若将水深栅格完整作为训练标签，会影响集成模型的拟合效果，故对水深栅格进行进一步处理。在洪涝风险评估中，通常将水深低于0.15 m的区域视为轻微积水区域而非涝区，故本文将低于该值的水深栅格设置为0。在此基础上，对不连续水深栅格，即与其他非0值栅格不相连的水深栅格进行过滤，如图5所示。




图5 栅格清洗示意

Fig. 5 Schematic diagram of raster cleaning

2.2.4 地形数据归一化

输入特征之间的计量单位和量纲存在差异，如果将数据直接用于训练，则会由于部分数据过大或过小，使模型的训练精度受到影响。除了构造的二维等值序列外，地形因子等输入数据需要进行归一化处理。数据分布情况不同，采用的归一化方法也存在差异，本文采用min-max最值标准化法，利用线性函数将输入数据转换至[0, 1]区间，转化公式为

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (14)$$

式中， x 为归一化之前的原始序列数据； x' 为归一化之后的序列数据。

由于秀水河流域的地形高程与坡度等地形因子存在较大起伏，且缺失值的高程即为最值，该归一化方法能较好地保留地形特征差异。

2.2.5 地形边缘补全

为了更好地在数据驱动模块中进行模型训练，通常将输入图像的宽度和高度填充或裁剪为等长，以提升模型训练的性能。在本文的集成模型中，输入特征的尺寸即为模拟区域的空间范围，即由输入的DEM尺寸决定。在此基础上，填充或裁剪为宽高相等的输入图像。

2.3 集成模型训练与超参数优化

2.3.1 集成模型训练

将流域洪涝时序数据集划分为训练集和测试集，在数据驱动模块进行集成模型的训练。STFS-Urban深度集成并优化了Transformer神经网络，利用自注意力机制考虑输入因子的全局特征，通过不断地迭代，调整网络的权重和偏置参数，将预测结果与物理模型模拟结果之间的差异最小化，集成模型Transformer结构如图6所示。集成模型训练的主要流程分为以下步骤。

(1)模型前馈传播。训练过程从模型参数的初始化开始，这些参数通常是随机的。然后使用一系列矩阵乘法和非线性激活函数，将输入样本在网络中进行前馈传播。

(2)损失函数计算。将前馈传播计算得到的水深预测值与作为训练标签的物理驱动模拟水深进行对比，利用损失函数衡量两者之间的差异。选择合适的损失函数是集成模型保持水深预测具有合理低误差的关键，常见的损失函数包括交叉熵损失(Cross-Entropy)和均方误差(Mean Squared Error, MSE)。其中，交叉熵损失常用于分类任务，不适用于水深预测的目标。本文采用MSE作为损失函数

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (15)$$

式中， \hat{y}_i 为物理模型模拟的水深结果； y_i 为神经网络学习预测的水深结果。

(3)模型反向传播。基于链式求导法则，计算损失函数相对于网络权重和偏差的梯度。为了让损失函数达到最小，需要设置合理的学习率，进而提高网络训练的结果和效率。在此基础上，对网络的超参数进行更新，利用合适的优化算法，在损失函数的负梯度方向上调整网络的权重和偏置参数。

2.3.2 Transformer网络超参数搜索分析

超参数搜索优化的目标是找到给定神经网络模型的“最佳”超参数集，从而在验证数据上获得最佳性能，该过程可视为集成模型中数据驱动模块参数率定的过程。在神经网络模型训练之前，首先提取面

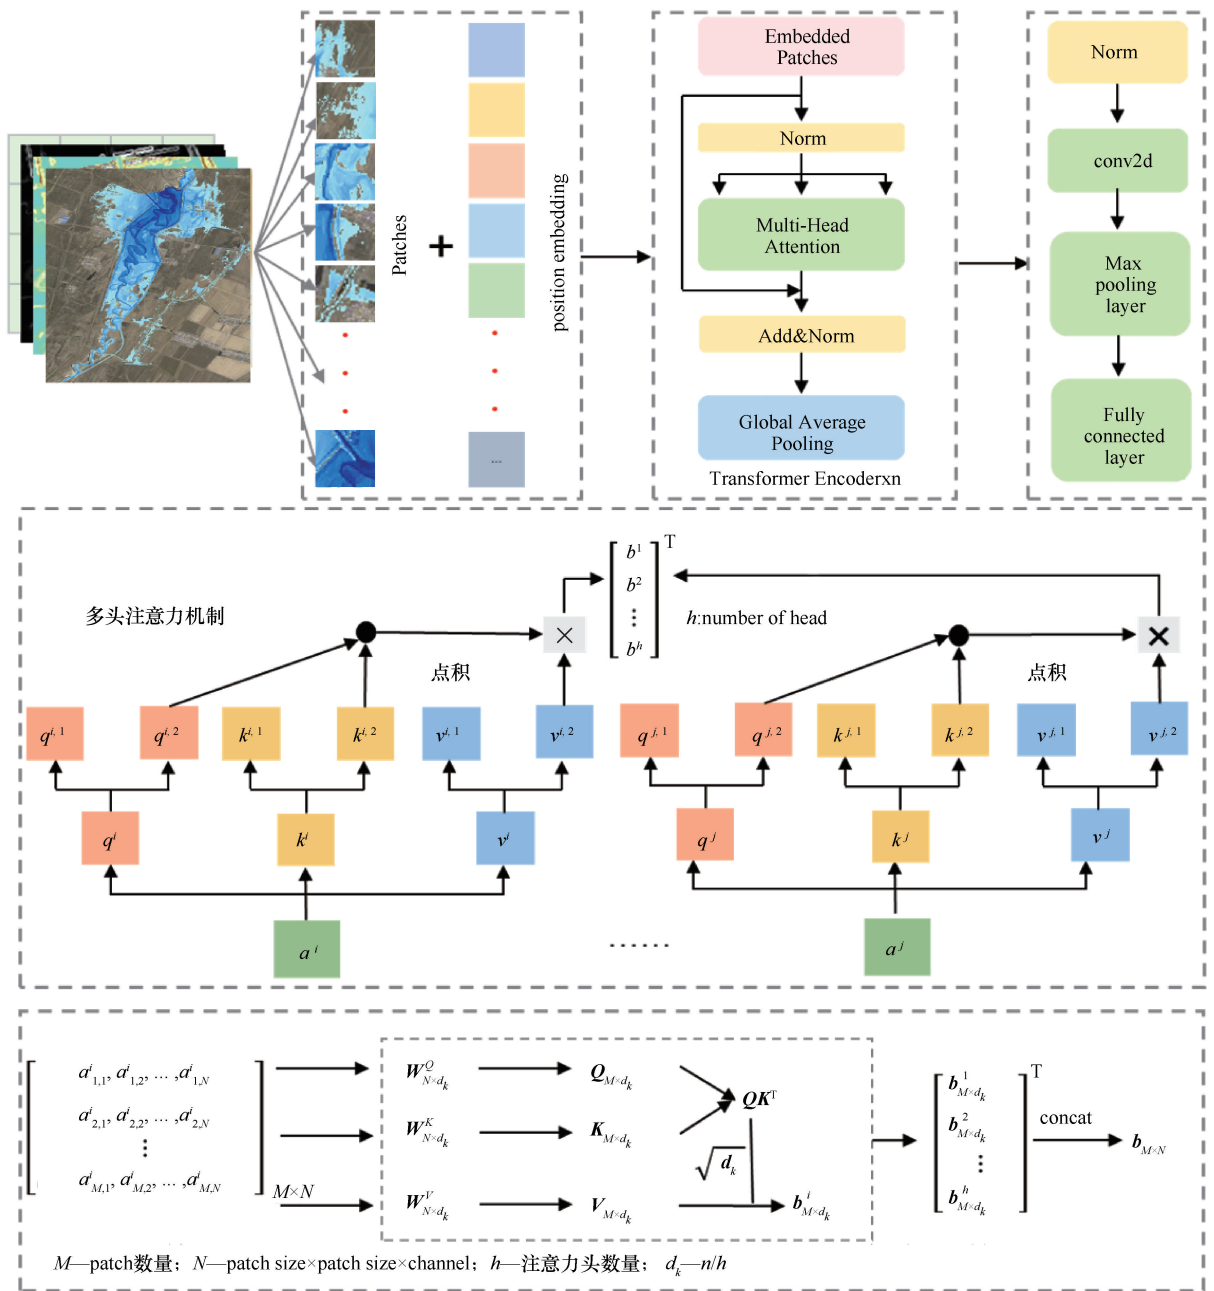


图6 流域洪涝集成模型 Transformer 结构

Fig. 6 Transformer structure of the integrated model

向不同洪涝模拟情景的神经网络模型超参数, 针对不同神经网络, 收集各自的超参数集合, 设定超参数集合的搜索范围, 具体如表 5 所列。

首先, 针对不同超参数组合进行模拟训练, 得到各自的流域洪涝时空推理结果, 通过对比预先设定的模拟结果阈值, 满足阈值要求即输出模型预测的结果, 不满足即进入超参数组合优化进程。其次, 在超参数优化过程中, 基于设定的多种误差指标, 定量计算不同超参数组合下的城市洪涝时空模拟预测误差, 形成超参数模拟误差池; 最后, 筛选误差池中的最优

结果, 作为神经网络模型的最优超参数组合。

在 Transformer 模型的训练过程中, 发现大部分超参数对网络的收敛效果影响较小。其中, 编码层的数量 depth 和多头注意力机制的头数 head 对模型收敛产生主要影响。在确认其他参数的基础上, 分析两种超参数在不同组合下的收敛效果, 对比分析结果如图 7 所示。

2.3.3 Transformer 网络超参数优化结果

经过多次迭代训练和超参数组合结果的对比, 确定 Transformer 神经网络的最佳超参数组合如表 6 所列。

表5 神经网络模型的超参数及其范围

Table 5 Hyperparameters of neural network models and their ranges

模型	超参数	参数含义	选取范围
Transformer	Encoder Layers	编码器层数	3~6
	Embedding Size	模型的嵌入维度	由输入尺寸决定
	Header Number	注意力头数量	[2, 4, 8, 16]
	Dropout Rate	丢弃率	0~0.5
	Patch Size	Patch 大小	[8, 16, 32]
	Pool Class	池化层类型	Average/Max
	Pool Size	池化层大小	[2, 4]
	Batch Size	批大小	[2, 4, 8, 16, 32]
	Epoches	迭代次数	100/模型收敛阈值

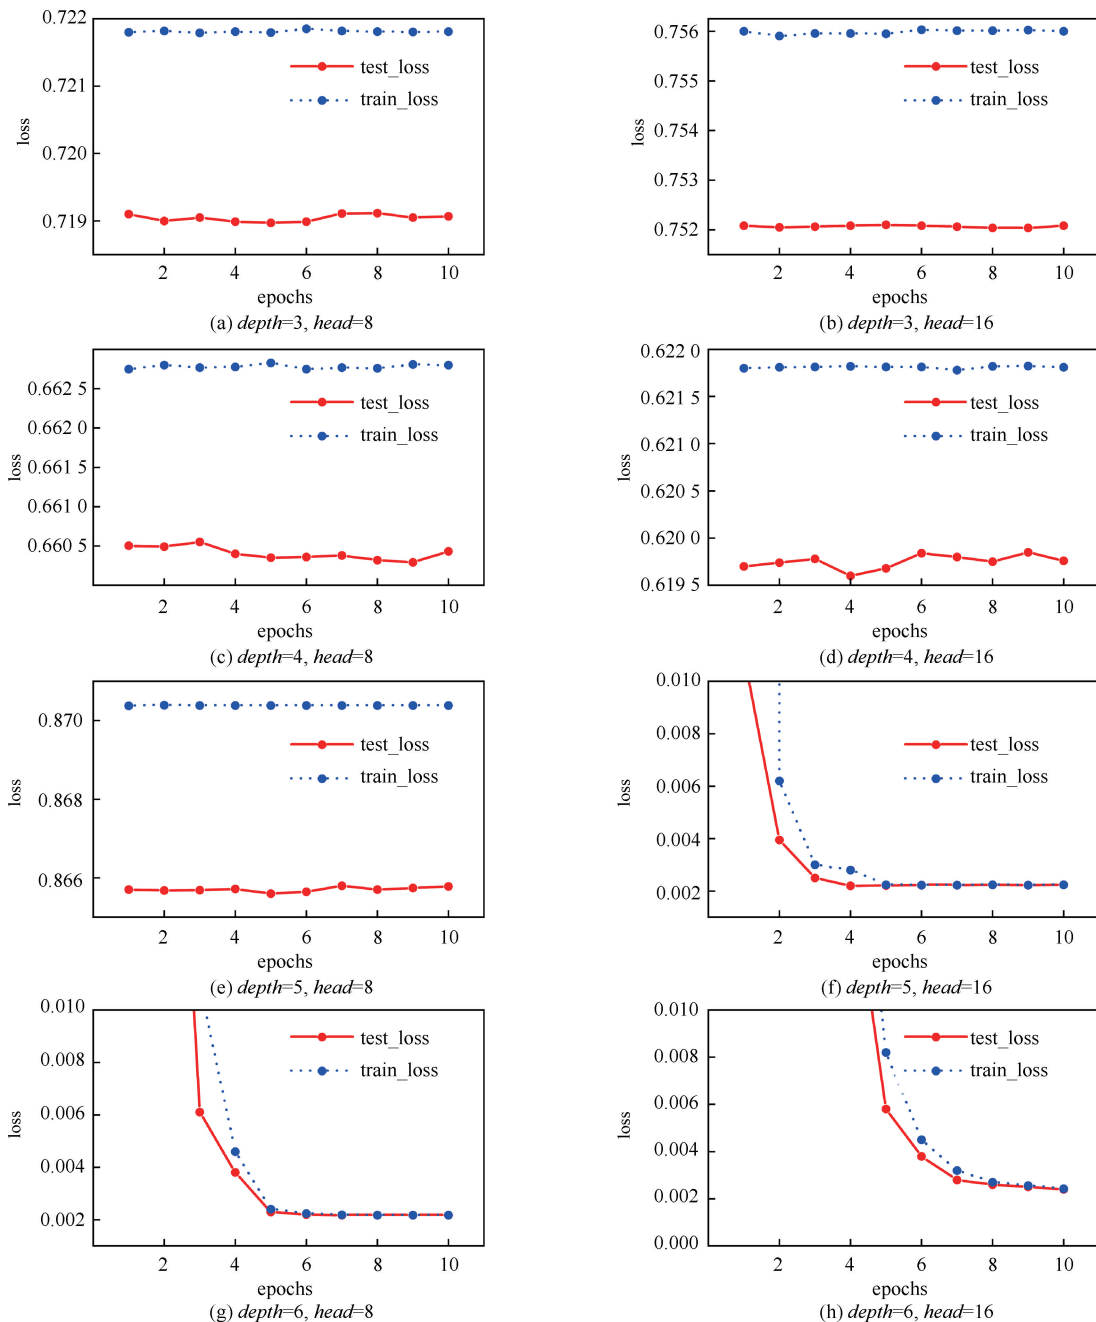


图7 不同编码层和注意力头数下的性能对比

Fig. 7 Performance comparison under different encoding layers and numbers of attention heads

表 6 最优 Transformer 神经网络超参数组合

Table 6 Optimal hyperparameter combinations for the Transformer neural network

超参数	数值
编码器层数(Encoder layers)	5
注意力头数量	16
Patch 块尺寸	16
批大小(batch size)	16
丢弃比例(dropout rate)	0.1
迭代次数(epochs)	100

在 Transformer 网络中, 首先利用 16×16 的 Patch 尺寸, 将输入图像切分并展平, 合并为一个新数组。在此基础上, 设定 5 层编码层, 每层编码层的注意力头数量为 16。此外, 试验过程中发现, 传统的 MLP 层结构会导致 Transformer 模型在做回归任务时产生内存溢出, 因为图像之间的线性连接会导致网络参数数量呈指数倍增加。因此, 为综合提升模型的训练效率, 将该层改造为卷积层加全连接层的组合。并对卷积层和全连接层的超参数进行搜索优化。为更清楚表达, Transformer 网络模型的完整结构如表 7 所列。基于超参数优化搜索得到的最终模型在测试集中取得了最佳性能结果, 可用于流域洪涝的时空模拟。

3 流域洪涝过程模拟结果分析

3.1 秀水河流域洪涝模拟

2022 年 7 月, 辽宁出现历史同期最强降雨过程, 辽河、绕阳河、秀水河等河流出现中型和小型洪水。选取秀水河流域 2022 年 7 月 6 日与 2022 年 7 月 28 日两场典型暴雨观测数据, 如图 8、图 9 所示, 构建多尺度降雨时空网格, 基于超参数优化后的 STFS-Urban 集成模型进行预见期为 48 h 的流域洪涝情景模拟, 统计模拟得到的秀水河径流过程水位值, 并与公

主屯水文站监测数据进行对比验证, 如表 8 所列。结果表明, 在“2022-07-06 场次”洪涝事件中, 模型预测水位与实测水位差值均小于 0.45 m, 误差在 1.2% 以内, 预测峰现时间与实测峰现时间误差为 1.83 h; 在“2022-07-28 场次”洪涝事件中, 模型预测水位与实测水位差值均小于 0.5 m, 误差在 1.5% 以内, 预测峰现时间与实测峰现时间误差为 1.17 h。总体上, STFS-Urban 集成模型对秀水河流域洪涝过程的洪水预测结果和变化趋势与实测值相近, 具有良好的模拟精度。

3.2 结果讨论

为进一步评估流域洪涝集成模型的预测精度与时间性能, 同步采用参数率定后的流域洪涝物理模型对“2022-07-06”与“2022-07-28”两场典型暴雨洪涝过程进行模拟, 洪涝预测结果均以 30 min 为时间步长进行输出, 共得到 96 帧淹没预测结果。由于数量较多, 取峰现时刻附近模拟淹没范围与淹没水深分布情况作为对比展示, 如图 10、图 11 所示。

(1) 洪涝演进预测效果。由模拟结果可以看出, 受降雨空间异质性影响, 随时间推进, 流域部分低洼地带产生离散涝区, 随雨强增加逐渐向干支流河道汇聚; 秀水河支流汇入干流水量逐渐增多, 干流河道水位显著上涨, 水流由中心河道向两侧河漫滩溢流, 但始终被河岸堤坝所约束, 并未发生漫坝、溃坝现象。物理模型与集成模型对于两场洪水场景所预测的淹没水深相近, 淹没范围与影响地点较为吻合, 对于流域洪涝过程表现出一致的演变态势与分布特征。查阅 2022 年 7 月水文站监测记录, 在“2022-07-06”与“2022-07-28”暴雨期间, 秀水河道充盈, 水位抬升, 流域内未发生大面积淹没事件, 模拟结果符合实际情况。

表 7 Transformer 模型的神经网络结构

Table 7 Neural network architecture of the Transformer model

隐藏层名	参数设置	输出尺寸	参数数量
Patch 嵌入层	卷积核大小 1, 输出特征 32	[16, 196, 256]	0
Position 嵌入层	—	[16, 32, 224, 224]	0
编码层 1	注意力头数 16, 激活函数 RELU	[16, 196, 256]	525, 568
编码层 2	注意力头数 16, 激活函数 GELU	[16, 196, 256]	525, 568
编码层 3	注意力头数 16, 激活函数 RELU	[16, 196, 256]	525, 568
编码层 4	注意力头数 16, 激活函数 GELU	[16, 196, 256]	525, 568
编码层 5	注意力头数 16, 激活函数 GELU	[16, 196, 256]	525, 568
Resize	—	[16, 224, 224]	0
卷积层 1	卷积核大小 9, 步长 7	[16, 196, 256]	327936
全连接层	输入 1 024, 输出 50 176	[16, 1 024, 50 176]	51 380 224

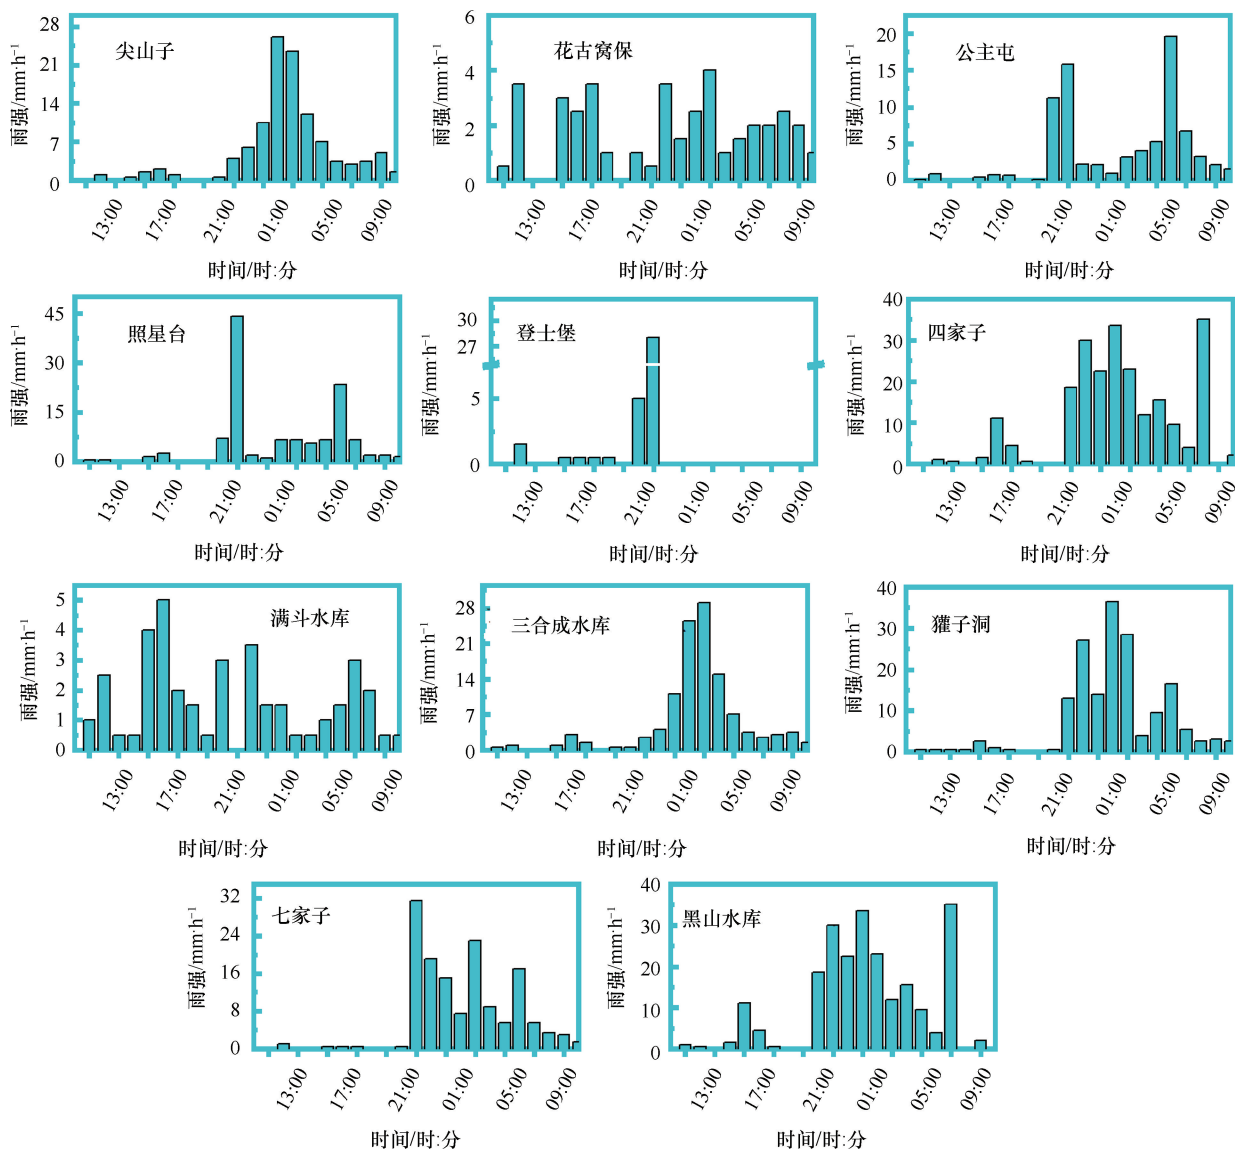


图8 2022-07-06 场次降雨过程

Fig. 8 Rainfall processes for the events on 2022-07-06

(2) 洪涝模拟时间性能。为评估两种模拟方式的时间性能,在模拟时均采用相同配置计算机进行模拟(Intel Core i9-13900HX 处理器, 32 GB 运行内存, NVIDIA GeForce RTX 4080 显卡)。对洪涝物理模型而言,模拟时长即为单次模拟的耗费时间;对于集成模型而言,模拟时长为每个匹配时刻下输入样本的预训练模型模拟时长总和。据此,两场降雨所对应的洪涝物理模型和集成模型运行时间对比结果如表9所列。

可以看出,集成模型模拟时效较物理模拟提高了31~34倍,流域洪涝物理模型在模拟一场降雨事件时,耗费的时间随输入DEM的空间分辨率以及输入降雨的时间步长增加呈指数型增长。其主要耗时原

因,是模型程序在运行时需要随时间步长在每个栅格进行物理参数迭代计算,以维持水量平衡。而集成模型在进行驱动模拟时兼具了深度学习的高效率优势,在时间性能上相比传统的物理驱动模型具有显著提升。

4 结论

本文基于STFS-Urban,构建了流域洪涝集成模型,以2022年7月6日与7月28日两场典型暴雨事件为例,对秀水河流域的洪涝过程进行模拟与分析。通过将模拟结果与水文站点监测数据进行对比分析,验证了模型的可行性与适用性,得出的主要结论如下。

(1) 在突发暴雨情景下,短时间内流域地表汇入

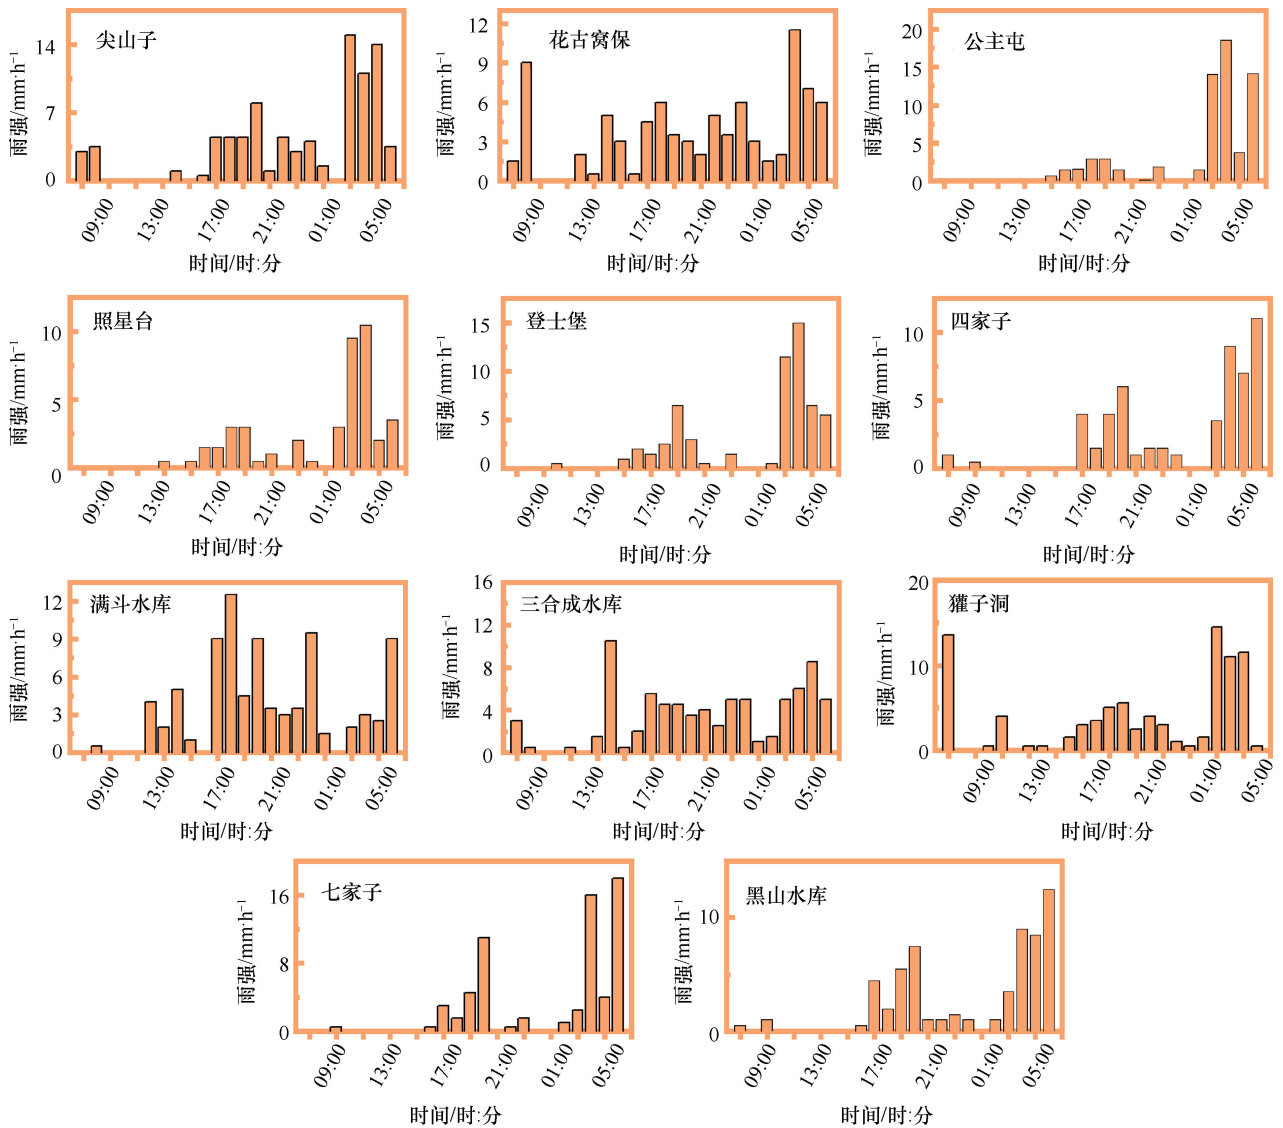


图9 2022-07-28 场次降雨过程

Fig. 9 Rainfall processes for the events on 2022-07-28

表8 STFS-Urban 集成模型水位预测值与实测值对比

Table 8 Comparison of predicted water levels from the STFS-Urban integrated model with observed values

监测时间/ 月-日 T时:分	2022-07-06 场次			监测时间/ 月-日 T时:分	2022-07-28 场次		
	实测值/m	预测值/m	误差/%		实测值/m	预测值/m	误差/%
2022-07-06 T 14:00	35.385	35.343	0.1	2022-07-28 T 14:00	35.405	35.753	1.0
2022-07-06 T 20:00	35.315	35.244	0.2	2022-07-29 T 08:00	35.815	36.003	0.5
2022-07-07 T 06:25	36.265	36.568	0.8	2022-07-29 T 12:00	36.245	36.672	1.2
2022-07-07 T 08:00	36.375	36.609	0.6	2022-07-29 T 14:00	36.425	36.925	1.4
2022-07-07 T 14:00	37.255	36.951	0.8	2022-07-29 T 20:00	37.025	37.359	0.9
2022-07-08 T 14:00	37.385	37.816	1.1	2022-07-30 T 08:00	37.375	37.813	1.2
2022-07-08 T 20:00	37.105	37.547	1.2	2022-07-30 T 14:00	37.225	37.414	0.5
峰现时间	8日 14:40	8日 16:30	1.83 h	峰现时间	30日 12:10	30日 13:00	1.17 h

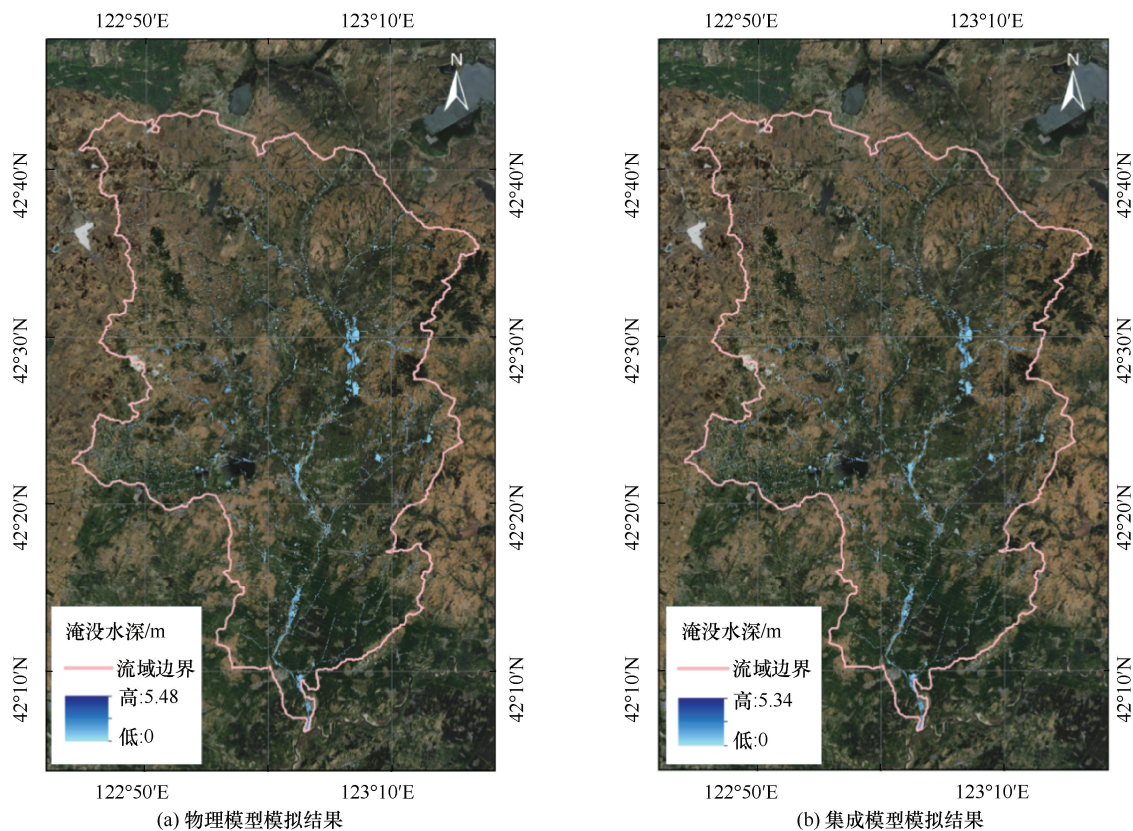


图 10 研究区域 2022-07-06 场次洪峰时刻洪水淹没范围

Fig. 10 The flood inundation extent at the peak flood stage in the study area on 2022-07-06

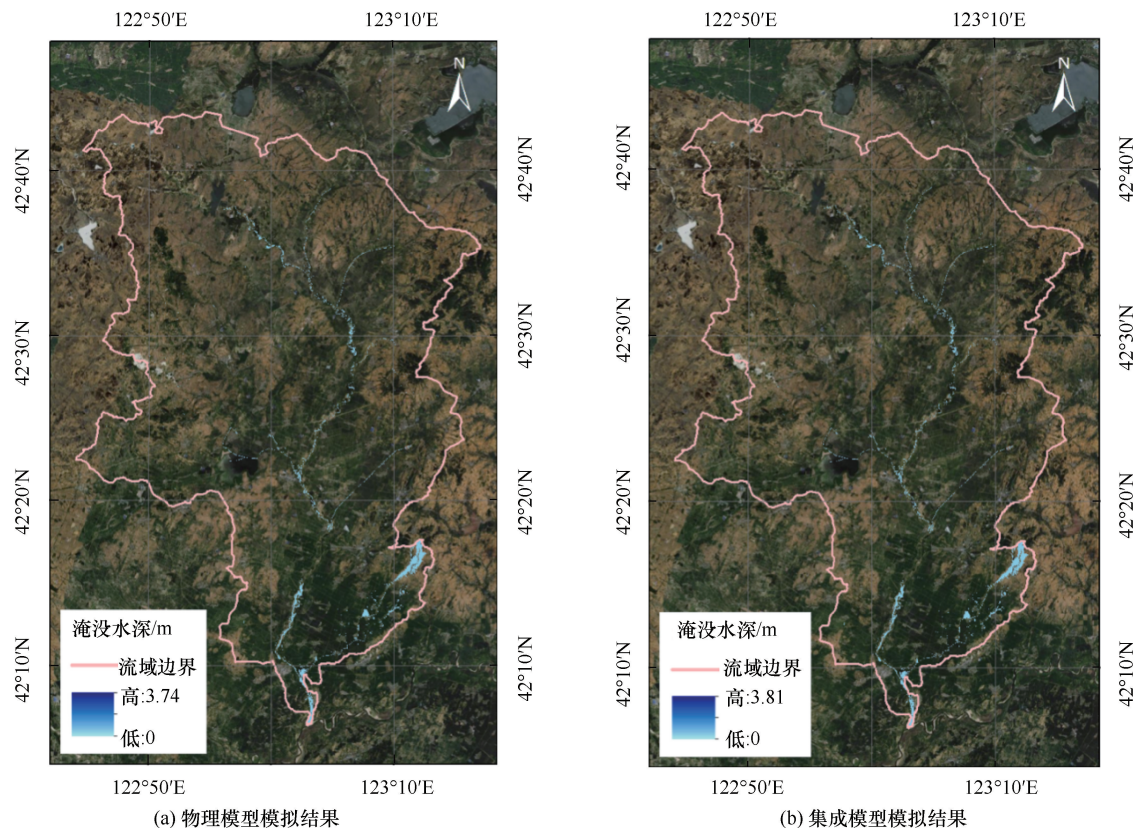


图 11 研究区域 2022-07-28 场次洪峰时刻洪水淹没范围

Fig. 11 The flood inundation extent at the peak flood stage in the study area on 2022-07-28

表9 模型运行时间对比

Table 9 Comparison of model run time

降雨场次	物理模型模拟耗时/min	集成模型模拟耗时/min
2022-07-06	24.8	0.8
2022-07-28	37.4	1.1

大量降水, 雨水无法迅速渗透到地下, 形成地表径流并流向河道。秀水河流域支流众多, 随着径流的迅速汇集, 河道中的水量迅速增加, 导致河道水位显著上涨。当河道水位超出堤岸或河道自身的承载能力时, 水体溢出河道, 漫流至周围低洼地区, 引发洪涝。

(2)STFS-Urban 流域洪涝集成模型基于地形地貌特征与水动力学基本原理, 充分考虑了流域降雨空间异质性、下垫面影响因子与模型计算参数对河道、河漫滩产汇流过程的影响, 能够较好地模拟流域洪涝过程, 模拟结果可为流域洪涝灾害风险评估、预报及预警提供全面数据支撑。

(3)STFS-Urban 流域洪涝集成模型利用深度学习方法进一步对洪涝物理模型进行模仿学习, 从中学习到更丰富的知识, 能够实现洪涝机理知识和时空大数据相互促进的耦合集成, 为解决现有物理驱动和数据驱动方法在流域洪涝模拟时存在的局限性问题提供了新的解决思路。

参考文献 (References):

- [1] 徐宗学, 陈浩, 任梅芳, 等. 中国城市洪涝致灾机理与风险评估研究进展[J]. 水科学进展, 2020, 31(5): 713-724.
XU Zongxue, CHEN Hao, REN Meifang, et al. Progress on disaster mechanism and risk assessment of urban flood/waterlogging disasters in China[J]. Advances in Water Science, 2020, 31(5): 713-724.
- [2] 中华人民共和国水利部. 中国水旱灾害防御公报[R]. 北京: 中华人民共和国水利部, 2023.
Ministry of Water Resources of the People's Republic of China. China Flood and Drought Disaster Prevention Bulletin[R]. Beijing: Ministry of Water Resources of the People's Republic of China, 2023.
- [3] 刘勇, 张韶月, 柳林, 等. 智慧城市视角下城市洪涝模拟研究综述[J]. 地理科学进展, 2015, 34(4): 494-504.
LIU Yong, ZHANG Shaoyue, LIU Lin, et al. Research on urban flood simulation: A review from the smart city perspective [J]. Progress in Geography, 2015, 34(4): 494-504.
- [4] 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]. 暴雨灾害, 2019, 38(5): 416-21.
XIA Jun, WANG Huiyun, GAN Yaoyao, et al. Research progress in forecasting methods of rainstorm and flood disaster in China[J]. Torrential Rain and Disasters, 2019, 38(5): 416-21.
- [5] 臧文斌, 赵雪, 李敏, 等. 城市洪涝模拟技术研究进展及发展趋势[J]. 中国防汛抗旱, 2020, 30(11): 1-13.

- ZANG Wenbin, ZHAO Xue, LI Min, et al. Research progress and development trend of urban flood simulation technology [J]. China Flood & Drought Management, 2020, 30(22): 1-13.
- [6] 黄华兵, 王先伟, 柳林. 城市暴雨内涝综述: 特征、机理、数据与方法[J]. 地理科学进展, 2021, 40(6): 1048-1059.
HUANG Huabing, WANG Xianwei, LIU Lin, et al. A review on urban pluvial floods: Characteristics, mechanisms, data, and research methods[J]. Progress in Geography, 2021, 40(6): 1048-1059.
- [7] 林程, 吴辉明. 龙岗河流域 2023 年“9·7”极端特大暴雨洪涝反演分析[J]. 水利发展研究, 2024, 24(10): 117-125.
LIN Cheng, WU Huiming. Inverse analysis of flood caused by 2023 “9.7” extreme rainstorm in Longgang River basin [J]. Water Resources Development Research, 2024, 24(10): 117-125.
- [8] 丁雨淋. 水文变化驱动的暴雨-洪涝灾害主动模拟方法[J]. 测绘学报, 2016, 45(2): 252.
DING Yulin. Hydrological changes driven storm flood disaster simulation method [J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(2): 252.
- [9] 周紫蕊, 廖卫红, 雷晓辉, 等. 基于 InfoWorks ICM 的城市河网调控与分析: 以福州市仓山区龙津阳岐片区为例[J]. 南水北调与水利科技(中英文), 2023, 21(4): 770-779.
ZHOU Z R, LIAO W H, LEI X H, et al. InfoWorks ICM-based urban river network regulation and analysis: A case study of Longjin Yangqi area in Cangshan District, Fuzhou City [J]. South-to-North Water Transfers and Water Science & Technology, 2023, 21(4): 770-779.
- [10] 黄国如, 罗海婉, 陈文杰, 等. 广州东濠涌流域城市洪涝灾害情景模拟与风险评估[J]. 水科学进展, 2019, 30(5): 643-652.
HUANG Guoru, LUO Haiwan, CHEN Wenjie, et al. Scenario simulation and risk assessment of urban flood in Donghaochong Basin, Guangzhou[J]. Advances in Water Science, 2019, 30(5): 643-652.
- [11] 赵天逸, 成玉宁. 基于 CAESAR-Lisflood 的弯曲型河流景观演化与洪泛区治理: 以英国塞文河为例[J]. 风景园林, 2021, 28(2): 76-82.
ZHAO Tianyi, CHENG Yuning. Evolution of curved river landscape and flood plain management based on CAESAR-Lisflood: A case study of the Severn River in the UK [J]. Landscape Architecture, 2021, 28(2): 76-82.
- [12] 宋晓猛, 徐楠涛, 董子然. 变化环境下城市洪涝风险评估与调控策略[J]. 水利发展研究, 2025, 25(1): 56-64, 85.
SONG Xiaomeng, XU Nantao, DONG Ziran. Risk assessment and control strategies of urban flooding under changing environments [J]. Water Resources Development Research, 2025, 25(1): 56-64, 85.
- [13] 侯精明, 王俊琿, 同玉等. 基于非均匀网格的高效高精度洪涝过程模拟[J]. 工程科学与技术, 2021, 53(4): 53-62.
HOU Jingming, WANG Junhui, TONG Yun, et al. High-efficient and high-precision flood process simulation based on the Non-uniform Grid [J]. Advanced Engineering Sciences, 2021, 53(4): 53-62.
- [14] KABIR S, PATIDAR S, XIA X, et al. A deep convolutional neural network model for rapid prediction of fluvial flood inundation [J]. Journal of Hydrology, 2020, 590: 125481.

- [15] 王先伟, 宁亚洲, 方勇军, 等. 暴雨洪涝灾情快速监测评估技术框架体系与应用; 以 2022 年 6 月北江流域洪水灾情分析为例 [J]. 水利水电技术(中英文), 2023, 54(3): 1-20.
WANG Xianwei, NING Yazhou, FANG Yongjun, et al. A technique framework and implementation for rapid survey and assessment of flood disasters: A case study in the North River Basin in June 2022 [J]. Water Resources and Hydropower Engineering, 2023, 54(3): 1-20.
- [16] YANG M, ZHONG P-A, LI J, et al. Research on intelligent prediction and zonation of basin-scale flood risk based on LSTM method [J]. Environmental Monitoring and Assessment, 2020, 192(6): 387.
- [17] 李云良, 张奇, 李森, 等. 基于 BP 神经网络的鄱阳湖水位模拟 [J]. 长江流域资源与环境, 2015, 24(2): 233-240.
LI Yunliang, ZHANG Qi, LI Miao, et al. Using BP neural networks for water level simulation in Poyang Lake [J]. Resources and Environment in the Yangtze Basin, 2015, 24(2): 233-240.
- [18] SHU X, DING W, PENG Y, et al. Monthly streamflow forecasting using convolutional neural network [J]. Water Resources Management, 2021, 35(15): 5089-104.
- [19] SAWAF M B A, KAWANISI K, JLILATI M N, et al. Extent of detection of hidden relationships among different hydrological variables during floods using data-driven models [J]. Environmental Monitoring and Assessment, 2021, 193(11): 1-14.
- [20] AYOGBI J L, KESSERWANI G, SHAW J, et al. Second-order discontinuous Galerkin flood model; Comparison with industry-standard finite volume models [J]. Journal of Hydrology, 2021, 594: 125924.
- [21] 侯精明, 潘鑫鑫, 陈光照. 基于 AI 的洪涝过程快速模拟预报方法及应用 [J]. 中国防汛抗旱, 2024, 34(2): 1-7.
HOU Jingming, PAN Xinxin, CHEN Guangzhao. AI-driven rapid simulation and forecasting techniques for flooding processes and their practical application [J]. China Flood & Drought Management, 2024, 34(2): 1-7.
- [22] 方磊. 基于快速雨洪模型与机器学习算法的流域多尺度洪涝模拟与管理研究 [D]. 厦门: 厦门大学, 2021.
FANG Lei. Development of Rapid Flood Models and Machine Learning Methods for Multi-scale Flood and Waterlogging Simulation and Management [D]. Xiamen: Xiamen University, 2021.
- [23] 江威, 黄诗峰, 孙营伟, 等. 空天信息技术保障流域水安全: 进展与展望 [J]. 水利发展研究, 2025, 25(8): 79-86.
JIANG Wei, HUANG Shifeng, SUN Yingwei, et al. Aerospace information technology ensures basin water security: progress and prospects [J]. Water Resources Development Research, 2025, 25(8): 79-86.
- [24] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science [J]. Nature, 2019, 566(7743): 195-204.
- [25] 南卓铜, 舒乐乐, 赵彦博, 等. 集成建模环境研究及其在黑河流域的初步应用 [J]. 中国科学: 技术科学, 2011, 41(8): 1043-1054.
NAN Zhuotong, SHU Lele, ZHAO Yanbo, et al. Integrated modeling environment and a preliminary application on the Heihe River Basin, China [J]. Science China (Technological Sciences), 2011, 41(8): 1043-1054.
- [26] 杨可欣, 毛树怀, 王铎洋, 等. 未来土地利用情景下城市地表径流变化模拟预测研究 [J]. 水利水电技术(中英文), 2023, 54(11): 66-76.
YANG Kexin, MAO Shuhuai, WANG Luoyang, et al. Simulation and prediction study of urban surface runoff change under the future land use scenario [J]. Water Resources and Hydropower Engineering, 2023, 54(11): 66-76.
- [27] BERKHAHN S, FUCHS L, NEUWEILER I. An ensemble neural network model for real-time prediction of urban floods [J]. Journal of hydrology, 2019, 575: 743-54.
- [28] HUSSAIN F, WU R-S, WANG J X. Comparative study of very short-term flood forecasting using physics-based numerical model and data-driven prediction model [J]. Natural Hazards, 2021, 107(1): 249-84.
- [29] ZONGKUI G, YIWEN C, YU Z, et al. STFS-urban: Spatio-temporal flood simulation model for urban areas [J]. Journal of Environmental Management, 2023, 349: 119289.
- [30] 宗原, 郭守岩, 薛成谦. 基于 MIKE11 的山丘区中小河流治理措施探讨 [J]. 黑龙江水利科技, 2024, 52(11): 154-158.
ZONG Yuan, GUO Shouyan, XUE Chengqian. Investigation of management strategies for small and medium-sized rivers in hilly regions based on MIKE11 [J]. Heilongjiang Hydraulic Science and Technology, 2024, 52(11): 154-158.
- [31] 蔡崇杰, 沈优, 董宇, 等. 基于 HEC-RAS 和 MIKE 11 的黄花沟河道整治分析 [J]. 水科学与工程学报, 2024(5): 23-28.
CAI Chongjie, SHEN You, DONG Yu, et al. River regulation analysis of Huanghuagou based on HEC-RAS and MIKE 11 [J]. Water Sciences and Engineering Technology, 2024(5): 23-28.
- [32] 赵华青, 周璐, 赵然杭, 等. 基于 MIKE 耦合模型的平原区流域洪涝过程模拟 [J]. 中国农村水利水电, 2022(7): 97-102.
ZHAO Huaqing, ZHOU Lu, ZHAO Ranhang, et al. Flood process modeling in the plain basin based on MIKE coupling model [J]. China Rural Water and Hydropower, 2022(7): 97-102.
- [33] 王元疆, 江善虎, 凌子涵, 等. 基于降雨时空变化的山洪预警临界雨量 [J]. 南水北调与水利科技(中英文), 2024, 22(1): 90-98.
WANG Y J, JIANG S H, LING Z H, et al. Critical rainfall for flash flood warning based on rainfall uncertainty [J]. South-to-North Water Transfers and Water Science & Technology, 2024, 22(1): 90-98.
- [34] 张磊, 罗平平, 王小琿, 等. 1960—2019 年关中平原极端降水时空变化及非平稳性分析 [J]. 水利水电技术(中英文), 2023, 54(3): 35-46.
ZHANG Lei, LUO Pingping, WANG Xiaohui, et al. Spatial and temporal variation and non-stationary analysis of extreme precipitation in Guanzhong Plain from 1960 to 2019 [J]. Water Resources and Hydropower Engineering, 2023, 54(3): 35-46.

(责任编辑 王海锋)