

融合 ResNet-18 与水动力模型的洪水演进快速预测

童 超^{1,2}, 詹晗煜², 崔 罡², 刘 康², 欧阳磊², 肖宏宇²

(1. 武汉理工大学船海与能源动力工程学院; 2. 长江信达软件技术(武汉)有限责任公司)

摘要:为实现高精度和高效率洪水演进预测,结合数据驱动与物理建模的双重优势,提出了融合残差神经网络(ResNet-18)与水动力模型 Telemac2D 的洪水演进快速预测算法,将 Telemac2D 生成的高精度洪水淹没数据作为训练样本,构建了基于一维 ResNet-18 的深度神经网络模型,并利用该模型对黄柏河流域下游尚家河河段洪水淹没水深与演进路径进行了实时动态预测和对比验证。结果表明:构建的 ResNet-18 模型对 240 组测试集预报结果的平均绝对误差和均方根误差分别为 0.033 2 m 和 0.089 8 m,淹没范围的空间分布与 Telemac2D 模拟结果高度一致,相关系数达 0.998 1,对测量点水深的预测结果比卷积神经网络模型更精确,且计算效率相较传统水动力模型提升超 300 倍。
关键词:洪水演进;残差神经网络;深度神经网络;Telemac2D;卷积神经网络模型;黄柏河流域

Rapid flood evolution prediction by integrating ResNet-18 and hydrodynamic model//Tong Chao^{1,2}, Zhan Hanyu², Cui Gang², Liu Kang², Ouyang Lei², Xiao Hongyu² (1. School of Naval Architecture, Ocean and Energy Power Engineering, Wuhan University of Technology; 2. Changjiang Schinta Software Technology (Wuhan) Co., Ltd.)
Abstract: To achieve high-precision and high-efficiency flood evolution prediction, a rapid flood evolution prediction algorithm that combined the dual advantages of data driving and physical modelling was proposed by integrating the residual neural network (ResNet-18) and the hydrodynamic model Telemac2D. High-precision flood inundation data generated by Telemac2D were used as training samples to construct a deep neural network model based on the one-dimensional ResNet-18. This model was subsequently employed to conduct real-time dynamic predictions and comparative verification of flood inundation depth and evolution pathways in the Shangjia River section of the lower Huangbai River Basin. The results demonstrated that for the 240 test sets, the developed ResNet-18 model achieved a mean absolute error of 0.033 2 m and a root mean square error of 0.089 8 m, respectively. The spatial distribution of the predicted inundation extent exhibited a high degree of consistency with simulation results from Telemac2D, with a correlation coefficient of 0.998 1. Furthermore, the model provided more accurate water depth predictions at measurement points compared to the convolutional neural network model and enhanced computational efficiency by over 300 times relative to the traditional hydrodynamic model.
Key words: flood evolution; residual neural network; deep neural network; Telemac2D; convolutional neural network model; the Huangbai River Basin

洪涝灾害不仅会造成严重的公共财产损失,还可能造成重大人员伤亡,严重阻碍社会经济的可持续发展^[1]。目前对二维流域的洪水数值模拟主要是基于物理机制或者物理模型,虽能实现淹没过程的精细化模拟^[2-3],但完整洪水过程的模拟需要采用有限元、有限差分、有限体积等数值方法对复杂的偏微分方程进行离散,而线性矩阵方程的求解随着未知数的增多会导致计算资源消耗显著和效率低下等问题,难以满足实时预警的时效性需求^[4]。为了对洪灾发生地区的人民生命和财产进行安全转移和安置,快速响应紧急预警至关重要^[5]。

洪涝预警模型需兼顾时空预测精度与计算性能

的平衡。在此背景下,数据驱动模型通过机器学习算法构建输入输出间的非线性映射关系,在保持预测精度的同时大幅提升运算效率,有效破解了精度与效率的权衡难题^[6-7]。当前,基于深度学习的洪涝快速推演技术已成为智慧水利领域的前沿研究方向^[8]。然而,数据驱动的深度依赖大量洪水信息,现实中历史洪水数据往往存在缺失或记录不全的情况^[9]。基于物理机制的水动力模型(如 Telemac2D)可以有效还原某个特定区域内的洪水淹没进程,提供明确的水流数据信息,如流速、流量和淹没水深等,生成大量洪水数据,而深度学习算法可以通过构建网络模型对这些洪水数据进行信息提

基金项目:武汉理工大学科研启动基金项目(10940121028)
作者简介:童超(1993—),男,讲师,博士,主要从事海洋与河流水动力研究。E-mail:tongchao@whut.edu.cn

取并学习,从而对洪水演进进行预测。通过融合水动力模型的精度优势与深度学习模型的快速求解能力,构建双驱动预测架构,在继承物理模型泛化能力的同时,实现了洪水演进速度的指数级提升^[10]。长短期记忆网络(LSTM)由于具备学习长期依赖关系的能力被广泛应用于风暴潮、城市内涝以及洪水过程的预测^[11-13]。Zhou 等^[14]使用 LSTM 网络和贝叶斯优化技术在洪水预报中实现了 19 585 倍的速度提升;吴鑫俊等^[15-16]通过卷积神经网络(CNN)模型达到 400 倍加速比。研究数据表明,经过充分训练的深度学习模型具备实时预测能力,其通过模式识别替代传统水动力方程(如圣维南方程组)的迭代求解,突破性地将计算耗时从小时量级降低至秒级,这种范式转换既保留了物理模型对复杂过程的刻画能力,又借助深度学习实现了实时预测,为洪水预警提供了高效解决方案。

CNN 模型受益于分权和局部连接机制,可以有效减少可训练参数的数量和网络的复杂性,从而提高城市洪水淹没预测模型的效率。CNN 模型已被证明适用于漫滩淹没预测^[17]和最大淹没深度映射^[18],并因其强大的特征提取能力被广泛应用,但传统深层 CNN 模型仍然面临梯度消失和网络退化的问题^[19]。残差神经网络(ResNet)通过引入残差学习框架,将网络层重构为学习输入与输出的残差映射,有效缓解了上述问题。其核心残差块通过跳跃连接实现梯度直接传递,在网络深度显著增加的同时保持了训练稳定性,在 ImageNet 等任务中验证了其优化优势^[19]。近年来,ResNet 与水文模型的融合已在洪水预测中展现出高精度和强鲁棒性^[20]。但 ResNet 模型主要应用在对二维图像的特征提取中^[21-22],并且在洪水演进中的研究相对缺乏。

本文构建了一维 ResNet-18 模型,并应用于黄柏河流域下游尚家河河段 24 h 洪水淹没水深的动态预测,通过与 Telemac2D 模拟结果进行对比,验证了 ResNet-18 模型的精确性和高效性。

1 预测方法

1.1 方法流程

构建一维 ResNet-18 模型进行洪水演进快速预测包括 3 个主要步骤(图 1):

a. 多场景洪水数据集生成。基于研究区数字高程模型(DEM)、边界条件和重现期设计洪水流量过程等数据构建 Telemac2D,通过数值模拟生成多场景下的洪水演进时空数据集。

b. 一维 ResNet-18 模型构建。将洪水数据集划分为训练集、验证集和测试集,构建一维 ResNet-18

模型,对训练集和验证集的数据进行学习与时空特征提取,从而获得具有最优泛化性能的网络模型。

c. 洪水快速模拟和预测。以实时洪水流量序列作为输入,通过训练完备的一维 ResNet-18 模型实现洪水淹没水深和动态演进过程的实时预测与快速推演。




图 1 模型构建和洪水演进快速预测流程

Fig. 1 Flowchart of model construction and rapid flood evolution prediction

1.2 基于物理机制的水动力模型

实测洪水淹没数据的稀缺性制约了数据驱动模型的构建,尤其在获取全河段时空动态淹没特征方面存在较大困难。现行研究通常采用物理驱动范式,即基于关键节点位置的历史洪水观测数据,通过参数反演法率定河道曼宁系数,建立水动力数值模型。经校验的模型若满足设定的精度要求,则表明其具备可靠的多情景推演能力。此时可结合抽样技术,在不同重现期范围内生成概率分布完备的洪水演进数据集,为深度学习模型提供物理约束下的训练样本。该建模策略有效解决了传统数据驱动方法因样本不足导致的泛化性缺陷问题。

本文采用基于物理机制的 Telemac2D 构建数据集。该模型由法国电力集团开发,用于求解二维圣维南方程。其核心优势在于能够处理复杂地形与不规则边界条件,通过非结构化网格灵活刻画河道、洪泛区及近岸区域的空间异质性,已被广泛应用于河流洪水演进、溃坝模拟、河口潮汐动力、海岸大范围风暴潮及城市内涝等场景^[23-26]。模型通过隐式时间离散与特征线法保证计算稳定性,支持高分辨率时空模拟,并可通过曼宁系数等参数的率定实现与实际水文观测数据的高精度匹配。

1.3 神经网络模型

一维 ResNet-18 模型通过引入残差学习机制,有效解决了传统深层网络训练中的梯度消失与网络退化的问题^[19]。其核心思想是将网络层重构为学习输入与输出之间的残差映射,而非直接拟合目标

函数,从而降低了优化难度。在结构设计上,ResNet-18 模型有 4 个堆叠残差块,每一个残差块包括两个具有相同通道数的卷积层,每个卷积层均实行批归一化操作,并通过激活函数 ReLU (rectified linear unit) 进行激活。一方面,每个残差块输入端 x 直接通过跨层跳跃路径实现恒等映射传递到输出端;另一方面, x 又通过堆叠的非线性层路径拟合映射 $f(x)$ 。这保证了网络的错误率不会随着层数增加而增加,并使梯度通过跨层跳跃路径直接反向传播至浅层,显著提升训练稳定性。

CNN 模型作为对照组用于一维 ResNet-18 模型的验证。由 Lecun^[27] 等提出的 CNN 模型通常用于二维图像识别和视频处理,而一维 CNN 模型可用于一维序列信息的特征提取^[28-30]。CNN 模型主要由卷积层、池化层和全连接层组成,其结构能够丢弃无用信息,减少网络参数,加快模型训练速度。

1.4 样本数据格式

本文构建的一维 ResNet-18 模型通过训练样本数据构建非线性映射函数 $Y=F(X)$,实现输入样本 X 与预测目标 Y 的映射关系。针对 24h 连续洪水演进预测,模型输入参数集 X 包含时刻 t ,时刻 t 对应的洪水流量 Q_t 及设计洪水流量序列 $\{Q_1, Q_2, \dots, Q_{24}\}$,因此,每个样本 X 由 26 个特征参数构成。模型输出 Y 包含 p 个(文中 $p=64\ 712$) 网格节点的淹没水深值 $D_1, D_2, \dots, D_p$ 。单个 24h 连续设计洪水事件将生成 24 个时序样本,基于 500 场设计洪水构建的数据集共包含 $N=500\times 24=12\ 000$ 个样本,按分层抽样原则随机划分为训练集(样本数占比为 80%,样本数为 9 600)、验证集(样本数占比为 18%,样本数为 2 160)和测试集(样本数占比为 2%,样本数为 240)。

利用最大-最小标准化方法将输入特征值线性映射至 $[0, 1]$ 区间,以消除量纲差异对模型训练的影响。对于 24h 淹没水深的动态预测,只需输入场次洪水数据格式,将训练好的神经网络模型循环调用 24 次,即可得到 24h 淹没结果,形成动态洪水淹没时空图。

1.5 模型参数设定与训练

作为对照,在一维 CNN 模型中,设 3 层卷积层,设置各层特征通道数分别为 32、64、128,卷积核尺寸为 7;设 3 层全连接层,各层神经元数依次设置为 128、256、512。在卷积层后进行批量标准化操作,使用 ReLU 作为激活函数,并进行最大池化操作。全连接层的神经元随机失活率设置为 0.3。

在一维 ResNet-18 模型中,其结构首层为卷积核尺寸为 7 的卷积层,输出通道数设置为 64,后接

核尺寸为 5 的最大池化层。网络核心包含 4 个级联残差模块,各模块内部分别配置两个卷积层,卷积核尺寸均为 3,特征通道数随着 4 个残差模块逐级扩展为 64、128、256、512,通过跳跃连接实现梯度优化。最终通过全局平均池化将特征映射降维后连接到全连接层输出训练结果。

训练过程中采用 NAdam 优化器,训练时设置学习率为 0.001,批参数为 128,训练周期上限为 300。采用早停策略以控制过拟合风险,当验证集的训练损失函数值连续 30 轮未改善时则提前终止训练。该配置在保证模型收敛性的同时显著提高了训练效率。

为了评估网络模型预测效果,采用平均绝对误差(MAE)、均方根误差(RMSE)和皮尔逊相关系数(r)3 项统计指标进行综合验证。MAE 反映预测值与观测值的绝对偏差水平;RMSE 通过平方运算放大误差项的贡献,对异常值敏感,RMSE 越小,表示模型整体误差越小; r 表征预测值与观测值的线性相关性,当 r 趋近于 1 时,表示模型能准确捕捉淹没水深的变化趋势。

本文构建的一维 ResNet-18 模型基于 Python 编程语言开发,依托 PyTorch 2.2.0 深度学习框架实现,并利用 NVIDIA CUDA 11.8 工具包进行 GPU 加速,以优化训练过程的计算性能。本文采用电脑的 CPU 型号为 Intel-Ultra7-155H-1.40GHz, GPU 型号为 NVIDIA RTX 500 Ada Generation Laptop, GPU 内存为 4 GB。

2 实例验证

2.1 研究区概况

黄柏河流域是长江中游左岸的一级支流,地处鄂西北,发源于荆山脉南麓,有东、西两条支流。东支为主流,发源于湖北省宜昌市夷陵区樟村坪镇羊角山村黑良山,西支雾渡河发源于樟村坪镇殷家坪村曹家山。东、西两支在宜昌市夷陵区两河口汇合为干流,于宜昌市葛洲坝上游三江航道注入长江。本文采用黄柏河流域下游尚家河河段进行实例验证,河段长约 13.45 km,水面平均宽度约为 50 m,水流自北向南流经大中坝村,该村附近的河道地势平坦,在洪峰汛期极易发生洪涝灾害。研究区概况如图 2 所示,高程数据在河道附近的分辨率为 $5\text{ m}\times 5\text{ m}$,远离河道的分辨率为 $15\text{ m}\times 15\text{ m}$ 。在 Telemac2D 的数值模拟中,将入口边界设置成流量边界,出口边界设置成了水位边界,采用超临界流求解洪水过程。在数据集的生成过程中,提前设定小流量进行模型预热计算,以保证河道内初始水位较低。




图2 尚家河概况

Fig.2 Overview of the Shangjia River

2.2 多场景洪水流量过程设计

由于缺乏目标河段的洪水淹没测量信息,需要通过人工合成不同洪水流量过程,而增加可用洪水淹没情景的数量是构建神经网络学习样本的常见做法。以尚家河流域为例,采用设计的洪水流量曲线作为 Telemac2D 的上游流量输入,可生成大量样本,建立淹没数据集。利用研究区历史重现期峰值流量生成具有当地实际特征的洪水过程,对提高淹没数据集的代表性具有重要作用。本文根据尚家河流域历史洪峰记录设计洪水流量曲线的洪峰流量,以5年、10年、20年、50年、100年、500年一遇的标准进行设计,对应的洪峰流量分别为933、1450、2040、2830、3460、4980 m^3/s 。

为增强设计洪水过程线的多样性以提高模型的泛化能力,针对尚家河流域24 h洪水过程,基于自然洪水的发生概率特征,系统构建了单峰、双峰及多峰等峰型结构。其中单峰型结构覆盖前峰、中峰、后峰3种峰值出现时段,双峰型结构通过主副峰间隔时间、峰值比等参数实现形态多样化,根据概率大小,峰型中会添入部分多峰峰型,最终生成包含多重控制参数的500组样本曲线,涵盖不同频率范围的洪峰流量及各类峰型组合,图3给出其中20条流量曲线。




图3 设计洪水过程曲线

Fig.3 Design flood hydrographs

2.3 结果与分析

2.3.1 误差统计与对比分析

为评价一维 ResNet-18 模型对测试集240组样本数据的预测效果,将该模型预测结果的评价指标与一维 CNN 模型进行对比,结果如图4所示。从图4可以看出,两者 r 相差不大,说明模型能很好地预测水深变化趋势,但 CNN 模型的 RMSE 变化幅度显著大于 ResNet-18 模型,表明 ResNet-18 模型得到的预测结果与 Telemac2D 结果更接近。ResNet-18 模型和 CNN 模型预测淹没水深的 r 均值分别为0.9981和0.9968, MAE 平均值分别为0.0332 m和0.0582 m,而 RMSE 平均值分别为0.0898 m和0.1286 m,因此,ResNet-18 模型整体预测效果优于 CNN 模型。




图4 CNN模型和ResNet-18模型对240组测试集预测结果评价指标

Fig.4 Evaluation indicators for prediction results of CNN and ResNet-18 models for 240 testing samples

为了验证模型的准确性和泛化性,设计了除500场设计洪水以外的两场24 h预见期洪水过程作为研究对象。如图5所示,洪水过程a为典型的单峰曲线,洪水过程b为典型的双峰曲线。利用一维 CNN 模型和 ResNet-18 模型对两个洪水过程的淹没水深进行预测,并与 Telemac2D 结果进行对比,图6为 CNN 模型和 ResNet-18 模型24 h淹没水深预测结果的评价指标。可以看出,神经网络模型对洪水过程a的预测结果显著优于对洪水过程b的预测结果,且 ResNet-18 模型24 h淹没水深预测结果的各评价指标皆优于 CNN 模型,表明 ResNet-18 模型能更好地预测

洪水淹没水深。表 1 为神经网络模型对 24 h 洪水过程淹没水深预测结果评价指标的平均值,从表 1 可以看出,ResNet-18 模型预测结果的 MAE 和 RMSE




图 5 设计洪水过程流量曲线

Fig. 5 Flow curves of design flood processes

表 1 24 h 洪水过程预测结果评价指标均值

Table 1 Average values of evaluation indicators for prediction results of 24-h flood processes

洪水过程	模型	MAE/m	RMSE/m	<i>r</i>
a	CNN	0.037 8	0.087 2	0.998 4
	ResNet-18	0.018 1	0.048 2	0.999 6
b	CNN	0.072 1	0.150 1	0.997 9
	ResNet-18	0.046 4	0.099 8	0.999 3

平均值约为 CNN 模型的 0.5 倍,均小于 0.1 m,且 *r* 均超过 0.999,说明 ResNet-18 模型预测结果的变化趋势与 Telemac2D 模拟结果高度相近。

2.3.2 洪水演进预测

针对 24 h 预见期洪水过程 b,以 1 h 为时间步长计算洪水淹没空间分布图,并选择了包括最大峰值、次峰值以及峰谷在内的 6 个典型时刻($t=2,6,8,11,15,22$ h)作为观测对象,验证 ResNet-18 模型的空间水位预测性能。将 ResNet-18 模型预测结果和 Telemac2D 模拟结果进行对比,从图 7 和图 8 可以看出,ResNet-18 模型预测的洪水淹没水深与 Telemac2D 模拟结果相近,不同时刻洪水影响的位置相吻合,淹没范围基本一致,淹没水深差异较小。结果表明,ResNet-18 模型能准确预测河流洪水淹没的涨落和演进过程。

2.3.3 洪水淹没水深预测

为了进一步评价 ResNet-18 模型对于局部网格节点淹没水深的预测效果,以洪水过程 b 为例,对 $t=4$ h 和 $t=6$ h 两个时刻 ResNet-18 模型和 Telemac2D 的结果进行对比,结果如图 9 所示。其




图 6 CNN 模型和 ResNet-18 模型 24 h 淹没水深预测结果的评价指标

Fig. 6 Evaluation indicators for 24-h prediction results of flood inundation depth by CNN and ResNet-18 models




图 7 一维 ResNet-18 模型对洪水过程 b 淹没水深预测结果

Fig. 7 Prediction results of inundation depth of flood process b by one-dimensional ResNet-18 model




图 8 Telemac2D 对洪水过程 b 淹没水深模拟结果

Fig. 8 Simulation results of inundation depth of flood process b by Telemac2D




图 9 洪水过程 b 网格节点淹没水深对比

Fig. 9 Comparison of inundation depths at grid nodes for flood process b

中, $t=4\text{ h}$ 对应图 6(d) 中洪水过程 b 预测误差最大的时刻(RMSE 为 0.25 m , MAE 为 0.11 m), $t=6\text{ h}$ 对应输入流量过程中最大洪峰出现的时刻(RMSE 为 0.046 m , MAE 为 0.018 m), 并选择了编号为 $39\,000\sim 40\,000$ 的网格节点作为观察对象。由图 9(a)可以看出, 在误差最大的时刻, ResNet-18 模型局部节点水深预测结果和 Telemac2D 模拟结果有一定偏差, 但整体变化趋势高度一致。由图 9(b)可以看出, 在最大洪峰出现的时刻, ResNet-18 模型对淹没水深的预测结果与 Telemac2D 模拟结果高度吻合, 对于该时刻的最大淹没水深, ResNet-18 模型预测结果与 Telemac2D 模拟结果分别为 17.00 m 和 17.02 m , 误差仅为 0.12% , 证明了 ResNet-18 模型具有良好的预测精度。

选取洪水淹没区域的 4 个网格节点(P1、P2、P3、P4)作为水深观测点(图 2), 并记录每个观测点的淹没水深历时曲线。P1 位于尚家河上游段的居

民楼附近; P2 和 P3 位于中下游段的漫滩区域, 接近大中坝村, 该处极易被洪水淹没; P4 位于最大淹没水深出现的位置附近。图 10 为 4 个观测点 24 h 预见期淹没水深历时曲线。与 Telemac2D 相比, ResNet-18 模型能够很好地捕捉洪峰到达时刻以及峰谷出现的位置和水深, 并能很好地预测不同点位的淹没水深。相比较而言, CNN 模型对水深的预测精度比 ResNet-18 模型相对较低, 对于峰值的捕捉偏差更大。从图 10 中还可以看出, 各模型 P3 结果相差较大, 主要因为 P3 位于浅滩区, 水深较浅。

2.3.4 模型计算效率

从模拟时间的角度来看, 在本文电脑配置的前提下, 训练完成后, ResNet-18 模型可以在 $1\sim 2\text{ s}$ 内完成空间淹没水深和研究区域内洪水演化过程的计算。对于每场洪水, 模型还可以输出 $5\text{ m}\times 5\text{ m}$ 空间分辨率和 1 h 时间分辨率的 24 张淹没图。Telemac2D 在单核进程下的模拟时间约为 1.3 h , 如




图 10 水深观测点 24 h 淹没水深历时曲线

Fig. 10 Duration curves of 24-h inundation depth at water depth observation points

果采用 MPI 24 核并行运算,所需时间依然为 7~8 min,ResNet-18 模型的计算效率为水动力模型的 300~400 倍。在进行预测时,ResNet-18 模型与水动力模型精度相似,但 ResNet-18 模型的计算效率显著提升。

3 结 语

与 Telemac2D 模拟结果相比,240 组测试集中,ResNet-18 模型淹没水深预测结果的 r 、MAE、RMSE 平均值分别为 0.998 1、0.033 2 m 和 0.089 8 m,ResNet-18 模型能够很好地模拟不同场景下洪水淹没演进趋势,对淹没范围及网格节点处淹没水深具有良好的模拟效果,且 ResNet-18 模型比 CNN 模型具有更高的预测精度。ResNet-18 模型具有较高的模拟效率,在与水动力模型精度相同的情况下,洪水演进计算效率提升了 300~400 倍,可满足洪水淹没实时预警预报的时效性要求。

基于数据驱动的 ResNet-18 模型本质上是学习特定区域(本文为尚家河河段)在训练数据涵盖情景下的洪水响应规律。若流域下垫面发生显著改变(如大规模清淤、堤防建设、土地利用变更),原有的输入-输出映射关系可能发生变化,模型预测性能可能下降,需要重新率定或训练。但对于地形地貌相对稳定或具有周期性监测的流域(如重要防洪保护区),本文方法具有显著优势。其核心价值在于,一旦完成物理模型数据生成和神经网络模型深度学习训练,在后续常态化预警调度中,即可实现秒级快速、高精度预测。未来将进一步对迁移学习、在线学习进行研究,并引入物理约束神经网络,以增强模型对下垫面轻微变化的适应能力,减少重复训练成本。

参考文献:

[1] Wilhelm B, Rapuc W, Amann B, et al. Impact of warmer climate periods on flood hazard in the European Alps[J]. Nature Geoscience, 2022, 15(2): 118-123.

[2] 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))

[3] 王昕泽,侯精明,王峰,等. 城市雨洪内涝三维实景动态模拟表达方法研究[J]. 中国防汛抗旱, 2023, 33(10): 52-57. (Wang Xinze, Hou Jingming, Wang Feng, et al. Research on the expression method of three dimensional real scene dynamic simulation of urban rain flood

waterlogging [J]. China Flood & Drought Management, 2023, 33(10): 52-57. (in Chinese))

[4] 黄国如,陈志威,曾博威. 城市洪涝模型及 CPU-GPU 异构并行计算技术研究进展[J]. 水利学报, 2023, 54 (6): 654-665. (Huang Guoru, Chen Zhiwei, Zeng Bowei. Research progress of urban flood model and CPU-GPU heterogeneous parallel computing technology [J]. Journal of Hydraulic Engineering, 2023, 54 (6): 654-665. (in Chinese))

[5] 吴仪,王运涛,杨云川,等. 基于 HEC-RAS 的胖头泡蓄滞洪区洪水模拟与灾损评估[J]. 水资源研究, 2020, 9 (1): 42-51. (Wu Yi, Wang Yuntao, Yang Yunchuan, et al. Flood simulation and disaster loss assessment of flood storage and detention areas based on HEC-RAS [J]. Journal of Water Resources Research, 2020, 9(1): 42-51. (in Chinese))

[6] Liao Yaoxing, Wang Zhaoli, Lai Chengguang, et al. A framework on fast mapping of urban flood based on a multi-objective random forest model [J]. International Journal of Disaster Risk Science, 2023, 14(2): 253-268.

[7] 杨哲,杨昆,吕娟,等. 基于改进的三层机器学习搜索法极端降雨区域频率估计[J]. 中国防汛抗旱, 2023, 33 (1): 44-51. (Yang Zhe, Yang Kun, Lyu Juan, et al. An improved three-layer machine learning searching algorithm for regional frequency analysis of extreme rainfall events [J]. China Flood & Drought Management, 2023, 33(1): 44-51. (in Chinese))

[8] 周戛,侯精明,陈光照,等. 基于机器学习的山洪灾害快速预报方法[J]. 水资源保护, 2022, 38 (2): 32-40. (Zhou Nie, Hou Jingming, Chen Guangzhao, et al. A rapid forecasting method for mountain flood disaster based on machine learning algorithms [J]. Water Resources Protection, 2022, 38(2): 32-40. (in Chinese))

[9] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378: 686-707.

[10] Cloke H L, Pappenberger F. Ensemble flood forecasting: a review [J]. Journal of Hydrology, 2009, 375(3/4): 613-626.

[11] 苑希民,黄玉啟,田福昌,等. 基于 LSTM-GM 神经网络模型的风暴潮增水预报方法[J]. 水资源保护, 2023, 39 (6): 8-15. (Yuan Ximin, Huang Yuqi, TIAN Fuchang, et al. Research on forecasting method of storm surge based on LSTM-GM neural network model [J]. Water Resources Protection, 2023, 39(6): 8-15. (in Chinese))

[12] 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))
- [13] 石卓,史东华,姚成,等. 基于径流模数的 LSTM 模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版),2024,52(3):51-57. (Shi Zhuo, Shi Donghua, Yao Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds [J]. Journal of Hohai University (Natural Sciences), 2024, 52(3):51-57. (in Chinese))
- [14] Zhou Qianqian, Teng Shuai, Situ Z, et al. A deep-learning-technique-based data-driven model for accurate and rapid flood predictions in temporal and spatial dimensions[J]. Hydrology and Earth System Sciences, 2023, 27(9):1791-1808.
- [15] 吴鑫俊,赵晓东,丁茜,等. 基于数据驱动的 CNN 洪水演进预测方法[J]. 水力发电学报,2021,40(5):79-86. (Wu Xinjun, Zhao Xiaodong, Ding Xi, et al. CNN flood routing method based on data-driven training[J]. Journal of Hydroelectric Engineering, 2021, 40(5):79-86. (in Chinese))
- [16] 廖耀星,高玮志,张轩,等. 基于深度学习和水动力模型的洪水演进快速模拟方法[J]. 中国防汛抗旱,2024,34(2):16-22. (Liao Yaoxing, Gao Weizhi, Zhang Xuan, et al. Rapid simulation of flood routing using deep learning and hydrodynamic model [J]. China Flood & Drought Management, 2024, 34(2):16-22. (in Chinese))
- [17] 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.
- [18] Löwe R, Böhm J, Jensen D G, et al. U-FLOOD-topographic deep learning for predicting urban pluvial flood water depth[J]. Journal of Hydrology, 2021, 603:126898.
- [19] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas:IEEE, 2016:770-778.
- [20] Liu Junfei, Liu Kai, Wang Ming. A residual neural network integrated with a hydrological model for global flood susceptibility mapping based on remote sensing datasets [J]. Remote Sensing, 2023, 15(9):2447.
- [21] 李华宝,张振,陈林,等. 基于残差网络的河流表面时空图像测速法[J]. 河海大学学报(自然科学版), 2023, 51(1):118-128. (Li Huabao, Zhang Zhen, Chen Lin, et al. Surface space-time image velocimetry of river based on residual network[J]. Journal of Hohai University (Natural Sciences), 2023, 51(1):118-128. (in Chinese))
- [22] 于梦琴,季青,张志明,等. 基于深度学习 SE-ResNet 模型的皖江洪水调蓄区湿地类型遥感识别[J]. 南京信息工程大学学报, 2025, 17(6):893-904. (Yu Mengqin, Ji Qing, Zhang Zhiming, et al. Remote sensing identification of wetland types in Wanjiang flood regulation area via deep learning SE-ResNet model [J]. Journal of Nanjing University of Information Science & Technology, 2025, 17(6):893-904. (in Chinese))
- [23] 李国一,邵薇薇,刘家宏,等. 基于 TELEMAC-2D 模型的济南市洪涝模拟及淹没分析[J]. 水资源保护, 2024, 40(5):46-52. (Li Guoyi, Shao Weiwei, Liu Jiahong, et al. Flood simulation and inundation analysis in Ji'nan City based on TELEMAC-2D model [J]. Water Resources Protection, 2024, 40(5):46-52. (in Chinese))
- [24] 邵蕊,邵薇薇,苏鑫,等. 基于 TELEMAC-2D 模型分析不同洪涝情景对城市应急响应时间的影响[J]. 清华大学学报(自然科学版), 2022, 62(1):60-69. (Shao Rui, Shao Weiwei, Su Xin, et al. Impact of various flood scenarios on urban emergency responses times based on the TELEMAC-2D model [J]. Journal of Tsinghua University (Science & Technology), 2022, 62(1):60-69. (in Chinese))
- [25] 刘家宏,李泽锦,梅超,等. 基于 TELEMAC-2D 的不同设计暴雨下厦门岛城市内涝特征分析[J]. 科学通报, 2019, 64(19):2055-2066. (Liu Jiahong, Li Zejin, Mei Chao, et al. Urban flood analysis for different design storm hyetographs in Xiamen Island based on TELEMAC-2D [J]. Chinese Science Bulletin, 2019, 64(19):2055-2066. (in Chinese))
- [26] 都利亚,王兆礼,祁旭阳,等. 基于 TELEMAC-2D 模型的城区水库溃坝洪水数值模拟:以广州市龙洞水库为例[J]. 地球科学与环境学报, 2022, 44(5):850-859. (Du Liya, Wang Zhaoli, Qi Xuyang, et al. Numerical simulation of dam-break flood in urban area based on TELEMAC-2D model: a case study for Longdong Reservoir in Guangzhou, China [J]. Journal of Earth Sciences and Environment, 2022, 44(5):850-859. (in Chinese))
- [27] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [28] Kiranyaz S, Ince T, Hamila R, et al. Convolutional neural networks for patient-specific ECG classification [C]//2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Milan:IEEE, 2015:2608-2611.
- [29] Kiranyaz S, Avci O, Abdeljaber O, et al. 1D convolutional neural networks and applications: a survey[J]. Mechanical Systems and Signal Processing, 2021, 151:107398.
- [30] Liao Yaoxing, Wang Zhaoli, Chen Xiaohong, et al. Fast simulation and prediction of urban pluvial floods using a deep convolutional neural network model[J]. Journal of Hydrology, 2023, 624:129945.

(收稿日期:2025-03-13 编辑:施业)