

DOI:10.3876/j.issn.1000-1980.2026.04.011

考虑物理约束的多要素洪水模拟 LSTM 模型

何 畅¹, 李致家¹, 牛颢然¹, 梁世强², 李京兵³

(1. 河海大学水文与水资源学院; 2. 北京市水文总站; 3. 安徽省水文局)

摘要: 针对用数据驱动模型替代传统水动力模型实现快速预报时存在模拟结果单一与缺乏可解释性的问题, 基于多任务学习框架, 构建了一种用于多要素联合模拟的 LSTM 模型, 并将要素间的拟合物理关系作为约束项加入损失函数; 结合随机森林、斯皮尔曼秩相关系数法与 PCA 主成分分析法的特征综合评价结果, 进一步探讨了模型可解释性的问题。基于二维水动力数值模型对屯溪区 17 场洪水过程模拟结果的数据库, 分别训练考虑物理约束前后的 LSTM 模型, 结果表明: 考虑物理约束后 LSTM 模型运算速度并未显著降低, 能够在 1 s 内实现多要素的模拟; 对于多场洪水的整体模拟, 考虑物理约束的 LSTM 模型效果更优, 水位、流量、流速和淹没面积的模拟精度分别提升了 20.38%、17.03%、4.02%、14.07%; 考虑物理约束的 LSTM 模型对小洪水的捕捉能力更强; 对常规洪水的模拟精度较高, 但在极端复杂情况下性能仍需提升。

关键词: 城市洪水; 多要素洪水模拟; 二维水动力模型; 物理约束; LSTM 模型

An LSTM model considering physical constraints for multi-factor flood simulation

He Chang¹, Li Zhijia¹, Niu Haoran¹, Liang Shiqiang², Li Jingbing³

(1. College of Hydrology and Water Resources, Hohai University; 2. Beijing Hydrological Station;
3. Anhui Provincial Hydrological Bureau)

Abstract: In response to the issues of single simulation results and lack of interpretability when using data-driven models to replace traditional hydrodynamic models for rapid forecasting, an LSTM model for joint simulation of multiple factors was constructed based on a multi-task learning framework, and the fitted physical relationships among factors were incorporated into the loss function as constraint terms. Furthermore, the interpretability of the model was explored by combining the comprehensive feature evaluation results of random forest, Spearman rank correlation coefficient method, and principal component analysis (PCA). Based on a database of simulation results of 17 flood events in Tunxi District by a two-dimensional hydrodynamic numerical model, the LSTM models with and without physical constraints were trained, respectively. The results indicate that the computational speed of the LSTM model with physical constraints does not decrease significantly, which can realize multi-factor simulation within 1 s. For the overall simulation of multiple flood events, the LSTM model with physical constraints performs better, and the simulation accuracies of water level, discharge, flow velocity, and inundation area are improved by 20.38%, 17.03%, 4.02%, and 14.07%, respectively. The LSTM model with physical constraints demonstrates a stronger capability in capturing small floods and higher accuracy in simulating regular floods, but its performance still needs to be improved under extremely complex conditions.

Key words: urban flood; multi-factor flood simulation; two-dimensional hydrodynamic model; physical constraint; LSTM model

受全球气候变化影响, 近年来我国极端强降水事件频发, 气候风险指数呈升高趋势^[1]。与此同时, 随着京津冀、长三角、粤港澳、成渝、长江中游等城市群的不断发展, 我国城镇化率快速提升, 对城市防洪排涝体系建设提出了更高要求。2021 年, 郑州市遭遇历史罕见“7·20”特大暴雨; 2023 年 7 月底至 8 月初, 受台风“杜苏芮”影响, 京津冀等地遭遇严重洪涝灾害, 均凸显了极端天气事件对城市安全构成的重大威胁, 也进一步强调了加强城市防洪排涝能力建设的紧迫性。提升城市洪水预报技术不仅关乎城市防洪排涝系统的完善, 更是有效精准防控城市极端暴雨洪水、实现高质量发展和高水平安全良性互动的重要基石和必要保障^[2]。

随着数值模拟技术的发展, 一二维水动力耦合模型因能准确反映建筑物周围的积水情况以及水流绕过

基金项目: 国家自然科学基金项目(52079035); 中央高校基本科研业务费专项资金项目(B240203007); 安徽省自然科学基金重点项目(2208085US06)

作者简介: 何畅(2001—), 女, 硕士研究生, 主要从事水文物理规律模拟及水文预报研究。E-mail: 15110551182@163.com

通信作者: 李致家(1962—), 男, 教授, 博士, 主要从事水文模型与水文预报研究。E-mail: zjli@hhu.edu.cn

建筑物的具体路径,在城市洪水预报中得到了广泛应用。众多研究表明,一二维耦合的水动力模型在提高洪灾预警的准确性方面具有显著优势^[3-6],但其伴随的更精细的网格划分与更为频繁的数据交互无疑给模型的计算带来了更大的负担,即使借助 GPU 的并行计算架构,对一场降雨事件的完整模拟仍需耗费数小时,这一时间成本对于防洪预报的时效性要求构成了严峻挑战。

随着多学科交叉研究的深入,研究焦点逐渐转向构建具有强大数据分析能力的人工智能替代模型,以提升洪水模拟的速度。但受限于洪泛区内匮乏的逐时段实测数据,替代模型通常需要依赖水动力模型的模拟结果,通过学习其输入与输出数据间的关系^[7],实现快速预报。在众多机器学习模型中,卷积神经网络(CNN)^[8]虽在图像等二维结构数据处理上表现出色,却难以捕捉洪水数据这类序列中的长期依赖关系,且对输入数据位置变化敏感;生成对抗网络(GAN)^[9]训练过程不稳定,易出现模式崩溃等问题,在洪水模拟所需的精准数据生成上存在挑战。长短期记忆神经网络(LSTM)相关研究论文的引用量曾登顶 20 世纪人工智能领域高被引论文的榜首^[10],又因其擅长处理时序数据中的长期依赖关系而被广泛应用于水文预报领域^[11-12],能有效克服其他模型在洪水模拟数据处理时面临的困境,成为洪水模拟研究中的有力工具。

值得注意的是,多数深度学习模型以数据拟合精度为核心优化目标,常忽略水文水力学基本规律,因此主动引入物理约束十分必要。对此,Yang 等^[13]基于水动力模型生成的城市洪水淹没数据,以及水文站实时水位数据构建的初始条件,开发了一个深度学习模型,该模型能充分考虑洪水淹没的物理机制与输入、输出特征属性,具有较高的鲁棒性。然而,现有的相关研究一方面更倾向于模拟单一洪峰,或者模拟淹没水深的时间序列,难以完整地反映实际情况;另一方面,机器学习本质上属于“黑箱”模型,其决策过程难以直观理解,其预测结果也缺乏明确的物理意义和可解释性。有学者尝试通过降阶近似、归因于输入信息、发掘内部特征等方法^[14]分析模型的内部机理以解决这一问题,Kratzert 等^[15-17]少数学者更是将这种思想运用到了洪水预报的算法分析中。至此,机器学习模型开始被视作“灰箱”模型^[18],针对模型可解释性继续开展研究逐渐成为提高其普适性与接受度的重要方向。

基于上述现状,为尽可能在提升计算效率与维持模型可信度之间寻求平衡,本文仅针对水文—二维水动力耦合模型中,对城市复杂地形洪水的模拟效用更好,但计算更缓慢的二维水动力模块^[19-20]搭建 LSTM 替代模型,以各要素之间存在的客观物理联系作为反向约束嵌入模型,使得模拟结果不仅符合数据拟合的要求,还遵循物理规律。

1 模型构建

1.1 二维水动力模型

本文研究采用非结构化网格有限体积法离散二维浅水方程^[21],网格糙率值依据 2015 年中国年度土地覆盖数据集(CLCD)的土地覆盖类型信息,分别赋值为:农田 0.08,森林 0.8,灌木 0.4,草地 0.05,水面 0.025,裸地 0.04,不透水层 0.025。研究聚焦于短期暴雨积水情况,不考虑渗透因素。

在进行离散数值计算时,对于每个控制体 V ,在时间 $[t_n, t_{n+1}]$ 上对浅水方程积分可得:

$$\int_V \left(\frac{\partial \mathbf{U}}{\partial t} + \frac{\partial \mathbf{F}(\mathbf{U})}{\partial x} + \frac{\partial \mathbf{G}(\mathbf{U})}{\partial y} \right) dV = \int_V \mathbf{S} dV \tag{1}$$

式中: $\mathbf{U}$ 为守恒向量; $\mathbf{F}(\mathbf{U})$ 、 $\mathbf{G}(\mathbf{U})$ 分别为 x 、 y 方向通量向量; $\mathbf{S}$ 为源项向量。

根据高斯散度定理,将通量向量的偏导数转化为控制体积边界上的通量积分,并用 n_x 、 n_y 分别表示单位外法向量的分量,转换关系满足:

$$\int_V \frac{\partial \mathbf{F}(\mathbf{U})}{\partial x} dV = \oint_A \mathbf{F}(\mathbf{U}) n_x dA \quad \int_V \frac{\partial \mathbf{G}(\mathbf{U})}{\partial y} dV = \oint_A \mathbf{G}(\mathbf{U}) n_y dA \tag{2}$$

式中: A 为控制体闭合边界。

将式(2)代入式(1),整理得到有限体积法核心离散积分格式:

$$\int_V \frac{\partial \mathbf{U}}{\partial t} dV + \oint_A \mathbf{F}(\mathbf{U}) n_x dA + \oint_A \mathbf{G}(\mathbf{U}) n_y dA = \int_V \mathbf{S} dV \tag{3}$$

数值求解时选用 Osher 黎曼近似解^[22]计算跨单元的水量、动量的法向数值通量,并依托通量的坐标旋

转不变性,在每个控制体内,将二维问题转化为一维问题求解。

1.2 多要素模拟的 LSTM 模型构建

1.2.1 模型及参数设定

LSTM 作为一种由循环神经网络发展而来的具备特殊门结构的模型,较循环神经网络(RNN)能更好地处理序列数据中的长期依赖关系。多任务学习(multi-task learning)^[23]旨在同时学习多个相关任务,通过利用任务间的共享信息来提高模型的泛化能力与学习效率。在水文要素的模拟中,搭建多任务学习框架有助于挖掘各个物理量间的内在联系,进而避免单独学习导致的信息孤立问题。

用 LSTM 模型基于多任务学习框架,实现多目标协同模拟之前,需要按时间序列组织数据,形成多个任务的输入输出数据。输入数据首先进入 LSTM 层实现共享特征提取,同时转换为一种隐藏状态。这个隐藏状态包含了时间序列中的趋势、周期性等关键信息,并将相关的特征向量进行融合。然后为每个模拟任务设置独立的输出层,以便隐藏状态映射到对应的模拟空间。此外,多任务学习的 LSTM 模型还可以为每个任务定义损失函数,并采用加权相加的方式将其组合。不同的权重能平衡各子任务的重要性,以实现不同的研究目标^[24]。

在为搭建好的 LSTM 模型选取特征(输入)与目标(输出)时,需要密切考虑二维水动力模型的运作机理。因此,将暴雨洪水过程的强相关数据选为特征,将二维水动力模型模拟得到的水位(Z)、流量(Q)、流速(v)与淹没面积(A_s)时间序列作为目标要素。本文研究编程环境为 Python 3.10.13,采用 TensorFlow 2.10.0 深度学习框架搭建模型。硬件方面配备 NVIDIA GeForce MX250 GPU,内存为 8GB,为模型训练与运算提供支持。

超参数的取值会直接影响 LSTM 洪水预报模型拟合(模拟)与预测的性能。在已有的工程实践中,多采用从具体问题中总结的经验调参。本文选用试算法来确定最优的超参数组合,得到的结果为:隐藏层数量 2,隐藏单元数 63,学习率 0.001,批次大小 32,训练轮数 100,滑动窗口 20,激活函数 Sigmoid,优化器 Adam。其中,隐藏层数量与隐藏单元数决定模型的学习能力,结合研究区域小尺度洪水模拟的特点及试算结果,学习率设为 0.001 恰好使得当前数据条件下的模型稳定收敛;训练轮数取值 100 能够确保模型充分学习数据特征。当验证集损失连续 10 个训练周期未下降时,早停函数被启用,训练提前终止,避免模型过拟合的同时降低计算成本。

1.2.2 考虑物理约束的 LSTM 模型

运用 LSTM 模型实现多目标模拟时,若仅孤立地考量每一项要素的拟合效果往往过于片面。事实上,各模拟要素之间普遍存在物理相关关系,这种内在联系在提升模拟精度和增强模型可解释性方面具有不可忽视的重要意义,将其作为约束条件引入模型中,本质上是为模型提供了关于问题的先验知识,有助于模型更合理地学习和模拟。

本文依据训练集上断面水位、流量、淹没面积的二维模拟结果,绘制水位-流量过程线与水位-淹没面积关系曲线,并拟合得出相应的物理关系 $y_1=f(x)$ 、 $y_2=g(x)$ 。在 LSTM 洪水预报模型训练过程中,通常以最小化损失函数为目标进行优化,直至模型在训练集样本上的输出与对应真实值的偏差最小^[25]。鉴于模拟要素间物理关系对提升模型性能的重要性,将上述拟合关系作为约束条件引入损失函数,即在原有的均方误差(MSE)基础上添加一个惩罚项。由此新的损失函数可以定义为:

$$L = E_{\text{MS}} + \lambda_1 (y_1 - \hat{y}_1)^2 + \lambda_2 (y_2 - \hat{y}_2)^2 \tag{4}$$

式中: L 为损失函数; E_{MS} 为 MSE; y_1 、 y_2 为流量和淹没面积的理论真实值; $\hat{y}_1$ 、 $\hat{y}_2$ 为训练集上的预测值; λ_1 、 λ_2 为表征权重的系数,用于平衡数据拟合损失和物理关系约束的损失。当 λ_1 、 λ_2 较大时,模型会更加注重满足物理关系;当 λ_1 、 λ_2 较小时,模型更侧重于数据拟合。

在参数选择方面,考虑物理约束的 LSTM 模型(以下简称“改进的 LSTM 模型”)沿用约束前 LSTM 模型的超参数组合,以便于更直观地呈现物理约束这一变量对模拟结果的作用。对 λ 的取值,通过量级敏感性分析发现,当 λ_1 、 λ_2 取 10^{-7} 时,物理约束项 $(y_1 - \hat{y}_1)^2$ 、 $(y_2 - \hat{y}_2)^2$ 的梯度贡献量级与原始 MSE 损失项达到动态平衡。具体而言,由于物理关系约束项本身具有强非线性特征(如水位-流量函数的梯度可达 10^4 量级),当 $\lambda > 10^{-5}$ 时,约束项主导梯度更新方向,导致模型陷入局部最优而丧失数据驱动优势;反之,当 $\lambda = 10^{-7}$ 时,约束项在反向传播中的有效梯度权重被控制在 MSE 梯度的 1%~5% 范围内,既能在参数空间中引导物理一

致性,又保留了 LSTM 模型对复杂水文响应的学习能力。这种弱约束机制与自适应正则化思想相契合,其有效性通过决定系数提升超过 20%得以验证,表明在保持数据驱动优势的同时,精微的物理导向能提升模型预测能力。

另外,在现有模型的基础上,增加随机森林(RF)算法^[26]来评价特征的重要性。对于流量边界、水位边界、降水量等输入特征,其对目标变量预测结果的影响主要依据 RF 算法中每棵决策树在节点分裂时对不同特征的利用情况,以及该特征对提升最终模拟结果准确性的实际贡献来综合衡量。

为提升特征评价结果的可信度,降低使用单一评价方法的局限性,进一步引入斯皮尔曼秩相关系数法^[27]与 PCA 主成分分析法^[28],综合评价特征的重要性。

1.3 评价指标

为验证基于 LSTM 模型的城市暴雨洪水模拟结果的准确性,采用平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)作为统一的评价指标。MAE 与 RMSE 的值越小,说明模型的模拟值与真实值越接近,模型的性能就越好。当 R^2 越接近 1 时,模型对因变量变异的解释程度越高。

在评估模型的整体精度时,主要依据熵权法^[29]将 RMSE 和 R^2 的权重均设为 0.4,MAE 的权重设为 0.3。这一权重分配方案基于数据本身离散程度,同时旨在突出 RMSE 对极端误差的敏感性以及 R^2 对数据拟合的解释能力,兼顾 MAE 所反映的平均误差情况。再对单一指标的精度提升率做加权平均,即可得到能够综合反映模型精度变化的百分比。这种方法能够有效整合不同指标的信息,为评估模型在洪水模拟中的性能改进提供一个全面且量化的依据。

2 实例验证

2.1 研究区域与数据

屯溪区地处皖南山区边缘、位于屯溪流域下游,是安徽省黄山市的中心城区,总面积 191 km²。该区属亚热带季风气候,雨量丰沛,年降水量约 1670 mm。区内河流总长度 126.16 km,分布密度为 0.8 km/km²。河网水系复杂,横江、率水分别由西北、西南入境,受益地地势影响,由四周丘陵向盆谷平原汇集,于镇海桥下汇合为新安江,途中佩琅河汇入,最终在王村出境。

二维模型以占地面积约 20 km² 的屯溪区沿河部分城区(图 1)为建模范围,计算域边界选取基于实际地形高点或密集建筑群等城市不透水边界。此类条件下,边界外降雨形成的地表径流因地形阻隔无法直接进入计算域,地下渗流也因人工构筑物拦截而通量极小,可近似视为“无水量交换”。经 50~100 年一遇的洪水过程粗略模拟,确保拟定边界处未发生水量交换,证实了该方案的可行性。继而将该区域划分成边长为 100 m




图 1 研究区域示意图

Fig. 1 Schematic diagram of study area

左右的 2 459 个三角网格^[30],鉴于模拟区域面积较小,研究采用屯溪水文站降雨数据作为全区域输入。

为确保所选次洪在洪峰、历时以及峰形分布等方面具备显著代表性,能够涵盖大、中、小不同洪量级,同时囊括陡涨陡落与缓涨缓落、单峰与多峰洪水等多种特性,选择 2008—2020 年共 17 场历史洪水数据开展模拟分析,具体包括横江、率水、佩琅河的上游流量边界、王村水位站的下游水位边界与屯溪水文站的时段降雨过程等。基于屯溪流域站点实测的降雨径流数据,率定栅格新安江模型^[31]参数,再依此确定上边界对应计算网格的流量过程;下边界水位则需在获取流量过程的基础上,根据站点实测的水位-流量(Z - Q)曲线得出。拟选取屯溪城区市政中心处一重要断面(断面 20)作为研究断面,依托二维水动力模型的模拟结果,构建支撑机器学习模型运算的数据集。其中,将 2008—2014 年共 13 场洪水资料作为训练-验证集以训练模型,2015—2020 年的 4 场洪水资料作为测试集以验证模拟结果。

2.2 模型模拟用时比较

对 17 场洪水过程开展水动力模拟,求得其平均耗时为 5 h。利用得到的数据分别训练 LSTM 模型和改进的 LSTM 模型,记录训练阶段与测试阶段的平均运算时长。结果显示,LSTM 模型的平均训练时长为 34.52 s,改进的 LSTM 模型平均训练时长为 38.12 s,运算耗时增加了 3.60 s,归因于考虑物理约束一定程度上增加了模型计算的复杂度。而测试阶段,改进前后的 LSTM 模型平均模拟用时分别为 0.69 s 和 0.73 s,差距微弱,不超过 0.1 s。综上可知,虽然改进的 LSTM 模型较 LSTM 模型在训练集与测试集上的运算耗时均有一定程度的增加,但相较二维水动力模拟以小时为单位的模拟时长,改进的 LSTM 能在 1 s 内完成场次洪水的多要素模拟,结果更全面,也满足了时效性要求。

2.3 模拟效果评价

2.3.1 多场次洪水的整体模拟

图 2 为改进前后 LSTM 模型在训练-验证阶段对水位 Z 、流量 Q 、流速 v 、淹没面积 A 模拟结果的总体误差分布态势(图中 MAE 和 RMSE 采用实测均值进行了无量纲化处理)。LSTM 模型的 MAE 箱体位置较高,中位数约为 0.022 5;而改进的 LSTM 模型 MAE 箱体位置更低,中位数约为 0.016 5,意味着该模型的模拟结果更接近真实值。对 RMSE 指标,LSTM 模型的箱体中位数约为 0.035 5,改进的 LSTM 模型中位数降至 0.027 0,进一步证实了改进的模型具有更高的精度和稳定性。改进的 LSTM 模型 R^2 的中位数约为 0.988,相比 LSTM 模型更接近 1,说明其对数据的拟合效果更佳。综合上述指标来看,改进的 LSTM 模型在性能上优于 LSTM 模型,对 4 个水力要素的综合模拟效果更好。此外,在超参数直接移用的情况下该模型性能仍有提升,这不仅验证了原 LSTM 模型超参数的可行性,还表明考虑物理约束能够有效优化模型性能。




图 2 训练-验证集上两种模型的多要素总体误差分布

Fig. 2 Multi-factor overall error distribution of two models on training and validation sets

在测试集上,两种 LSTM 模型的模拟结果如表 1 所示, R^2 均高于 0.90,最高值达 0.985 3,总体表现良好。具体而言,改进的 LSTM 模型 MAE 均低于 LSTM 模型;纵向来看,对水位、流量和淹没面积的模拟结果,改进的 LSTM 模型具有更低的 RMSE 和更高的 R^2 。由此可得,考虑物理约束后,模型的模拟偏差有所降低,表现明显更优。综合以上指标,易求得水位、流量和淹没面积的模拟精度分别提升了 20.38%、17.03%、14.07%。而对于流速,其模拟精度受模型优化的影响较微弱,仅提升了 4.02%。

2.3.2 典型场次洪水模拟

为探讨模型在场次洪水中的模拟精度,在测试集内选取 3 场典型洪水展开进一步分析。图 3 为二维水动力模型、LSTM 模型与改进的 LSTM 模型对典型场次洪水(2015080908)中各要素的模拟结果。

表 1 两种模型在测试集上的多要素模拟结果评价指标

Table 1 Evaluation indicators of multi-factor simulation results of two models on test set

模拟要素	MAE		RMSE		R^2	
	LSTM 模型	改进的 LSTM 模型	LSTM 模型	改进的 LSTM 模型	LSTM 模型	改进的 LSTM 模型
水位	0.1247	0.0887	0.2585	0.1881	0.9650	0.9849
流量	13.6554	9.3322	182.2208	153.6061	0.9166	0.9453
流速	4.5222	4.0071	0.0527	0.0519	0.9759	0.9759
淹没面积	4.7499	3.6464	56.5735	47.0298	0.9767	0.9853

注:水位、流量、流速、淹没面积的 MAE 和 RMSE 的单位分别为 m、m³/s、m/s、m²。表 2 同。




图 3 典型场次洪水要素模拟结果

Fig. 3 Simulation results of factors for typical flood events

由图 3 可见,改进的 LSTM 模型模拟结果与二维水动力模型的模拟值更为接近,特别是在流量变化较大的区域,改进的 LSTM 模型相较 LSTM 模型展现出更优的拟合效果,充分彰显了物理约束在较小量级、较长历时洪水过程模拟中的显著优势。分析表 1 数据可知,在考虑物理约束后,模拟结果的 MAE、RMSE 降低而 R^2 升高,各要素的模拟精度平均提升了 25.29%,与图 3 所示情况吻合。改进的模型在低流量条件下有更高的精度和稳定性。

不难看出,对同一场洪水而言,模型对不同要素的模拟效果往往呈现出十分近似的规律,图 4 给出了另两场典型洪水中更具代表性的水位模拟结果。




图 4 典型场次洪水的水位模拟结果

Fig. 4 Water level simulation results for typical flood events

2016071420 是陡涨陡落的尖瘦型洪水,具有一定的代表性和发生频率。水位模拟结果(表 2)显示,相较 LSTM 模型,改进的 LSTM 模型的拟合偏差更大。但不可忽视的是,即使改进的 LSTM 模型的模拟精度普

遍低于 LSTM 模型,其整体的拟合情况仍十分理想。结合 4 个要素的模拟结果评价指标发现, R^2 的最小值高于 0.98,最大值更是达到 0.9957,改进前后模型的模拟精度均处于较高水平。这是由于在当前的模型体系与数据条件下,模型自身已具备较强的模拟能力,物理约束的作用虽然存在,但相较于其他影响因素,其对模拟精度提升的边际效应已被削弱。

表 2 典型场次洪水两种模型模拟结果的评价指标

Table 2 Evaluation indicators of simulation results of two models for typical flood events							
洪号	模拟要素	MAE		RMSE		R^2	
		LSTM 模型	改进的 LSTM 模型	LSTM 模型	改进的 LSTM 模型	LSTM 模型	改进的 LSTM 模型
2015080908	水位	0.0962	0.0905	0.1740	0.1425	0.9433	0.9571
	流量	58.4749	13.2766	66.1791	56.7884	0.9061	0.9259
	流速	6.7443	6.5314	0.0515	0.0424	0.9293	0.9481
	淹没面积	7.7682	6.0935	46.5370	41.0116	0.9422	0.9516
2016071420	水位	0.0639	0.0587	0.0898	0.0954	0.9889	0.9867
	流量	5.9100	9.4056	21.7861	32.5906	0.9957	0.9901
	流速	2.5114	3.1429	0.0149	0.0221	0.9953	0.9893
	淹没面积	2.7993	3.8836	19.0180	23.9742	0.9928	0.9885
2020070604	水位	0.4487	0.3329	0.7113	0.5951	0.6820	0.9060
	流量	20.9793	19.0474	626.1127	575.4035	0.4178	0.5930
	流速	5.6620	8.5339	0.1051	0.1694	0.8483	0.8413
	淹没面积	6.9813	5.8038	139.1499	123.3115	0.8574	0.9272

对于 2020070604 号大型洪水,改进的 LSTM 模型较 LSTM 模型的拟合程度在水位变化较大的区域有明显提高。然而,在流量模拟方面,两个模型对峰值大小与峰现时间的模拟均较差。改进的 LSTM 模型模拟偏差较大,对于 A_s 曲线的拟合情况,该模型表现又更优。结合表 2 可知,虽然整体上改进的 LSTM 模型模拟结果的评价指标优于 LSTM 模型,但仍存在特殊情况。如考虑物理约束后,模拟流速的 MAE、RMSE 反而由 5.6620、0.1051 m/s 增大至 8.5339、0.1694 m/s。究其原因可能是双峰洪水的模拟难度高,而对于一些复杂的物理过程,在为模型增加约束条件后,需要匹配更深层次或更复杂的神经网络结构来捕捉物理规律。本文基于控制变量的原则,改进的 LSTM 模型未对除约束外的模型结构做出相应调整,因此造成模拟精度下降。

2.4 特征重要性分析

为提升模型可解释性并探究各输入变量对研究断面水力参数模拟的影响,本文采用 3 种方法求解特征重要性:RF 算法侧重预测贡献,斯皮尔曼秩相关系数法反映统计关联,PCA 主成分分析法体现整体变异贡献。为避免主观偏差,最终通过等权重运算整合 3 种方法求解结果,得到各输入特征的综合得分。具体而言,即系统评估横江流量边界(Q_1)、率水流量边界(Q_2)、佩琅河流量边界(Q_3)、王村水位边界(Z_1)与屯溪水文站的降水量(P)这 5 个因素对研究断面水位、流量、流速与淹没面积模拟结果的贡献程度,旨在通过综合分析,揭示不同边界条件和降雨过程在研究断面水力特性模拟中的相对重要性。

如表 3 所示,对于 RF 算法求得的特征权重与斯皮尔曼秩相关系数的绝对值,每一项输入特征对不同模拟要素的影响差异微弱,最大浮动不超过 0.01。而针对同一要素,不同输入特征的权重与斯皮尔曼秩相关系数却呈现出显著差异:RF 算法评价结果显示,对所有水力要素, Q_2 的权重均接近 0.98,而 Q_1 、 Q_3 、 Z_1 、 P 的权重均不大于 0.008,其中 P 的权重最低,这表明 Q_2 对下游水力要素的预测影响占绝对主导地位。斯皮尔曼秩相关系数的结果也呈现出相似的规律,所有特征与模拟要素的关联均显著($p=0$),但系数绝对值存在明显差异,按从高到低排序依次为 Q_2 、 Q_1 、 Q_3 、 Z_1 、 P ,流量边界 Q_2 与下游水力要素的单调关联性最强。不过,采

表 3 改进的 LSTM 模型输入特征评估

Table 3 Evaluation of input features for improved LSTM model												
输入特征	特征权重				斯皮尔曼秩相关系数绝对值				PCA 主成分分析			综合得分
	水位	流量	流速	淹没面积	水位	流量	流速	淹没面积	特征值	解释率/%	平均载荷绝对值	
Q_1	0.005	0.006	0.007	0.006	0.966	0.967	0.969	0.966	3.609	72.16	0.959	0.644
Q_2	0.983	0.987	0.979	0.983	0.975	0.976	0.976	0.975	0.954	19.07	0.928	0.962
Q_3	0.007	0.005	0.008	0.007	0.947	0.948	0.948	0.947	0.261	5.22	0.957	0.637
Z_1	0.003	0.001	0.004	0.003	0.922	0.922	0.923	0.922	0.108	2.17	0.914	0.613
P	0.001	0.001	0.001	0.001	0.237	0.238	0.240	0.237	0.069	1.38	0.274	0.171

用 PCA 主成分分析法得到的结论却有所不同,仅有 Q_1 的特征值大于 1,因此其作为核心信息主导整体变异。同时, Q_1 和 Q_3 的平均荷载绝对值相近,接近 0.96,二者对特征整体变异的解释力略高于 Q_2 ,而 P 的解释力仍为最弱。

通过等权重整合 3 种方法评价结果发现,率水流量 Q_2 的综合得分显著领先, P 始终为最次要特征。相较 RF 算法单独评估时过度突出 Q_2 、可能忽略其他特征的协同作用,组合评价结果使得 Q_1 、 Q_3 、 Z_1 的重要性被合理识别。结合客观事实剖析可知:屯溪流域的上游地势落差大,下游河道较为顺直且水系连通,为水流下泄创造了便利条件;加之多发的短历时暴雨使得洪水在河道内停留时间较短,下游水位便不会出现大幅上升,难以形成持续显著的顶托;降雨分布相对均匀,周边丰富的植被覆盖也可以减缓暴雨对城市的影响,再经过复杂的流域汇流等过程后,降雨对研究断面处的影响会受到明显削弱。此时,上游入流特别是率水的流量成为影响模拟结果的最主要因素,这与率水的年径流量居新安江各支流之首、对新安江水量补给作用突出的事实相呼应。因此,新安江下游断面的水力要素对率水流量变化更为敏感。上述分析既有助于理解机器学习模型的运算思维,也能为城市洪水响应工作提供参考。

3 结 语

本文构建了一个考虑物理约束的 LSTM 多要素洪水模拟模型,通过引入物理约束,增强了模型的科学性与合理性,提升了洪水模拟效率;同时,针对机器学习缺乏可解释性的问题,从事前解释与事后解释^[32]两个角度进行了剖析。屯溪区算例验证结果表明:①改进的 LSTM 模型能在 1 s 内完成场次洪水的多要素模拟,实现了高效运算。与传统的 LSTM 模型相比,该模型还显著提升了模型的模拟精度、稳定性和对数据的拟合能力,水位、流量、流速和淹没面积的模拟精度分别提升 20.38%、17.03%、4.02%、14.07%。②物理约束对 LSTM 模型在场次洪水各要素模拟中的影响较为复杂。通常考虑物理约束后,模拟结果的 MAE、RMSE 下降而 R^2 上升,各要素的平均模拟精度提升约 25.29%。但在部分场次的流量和流速模拟中,物理约束效果欠佳,这可能是由于不同场次的洪水特性各异,导致现有物理约束难以全面适配所有复杂情形。

探讨模型的可解释性,不仅加深了对算法逻辑的理解,还能指导实践。将物理约束加入 LSTM 模型,赋予了深度学习算法的决策过程以物理内涵;而特征综合评估结果表明,必须高度重视率水上边界入流的测量精度,而其他重要性相对较低的特征如降水量,根据模型复杂度与计算资源许可的要求,允许被适当简化处理。

本文研究在一定程度上为将深度学习模型更好地应用于水文模拟及预报领域提供了新的思考,但仍存在局限性,虽然模型在小洪水与常规洪水模拟中表现良好,但在极端复杂工况下性能仍有待优化,且模型对空间特征的刻画能力有限,未充分反映河道多断面间的水力联系与洪水演进的时空耦合关系。未来研究应从以下几方面开展:①通过数据增强技术合成极端工况数据,结合遥感影像等多源异构数据扩充训练样本,提升模型对复杂场景的适应性;②基于现有成果,搭建融合空间特征的深度学习模型,捕捉河道网络的拓扑结构与洪水传播规律,实现时空协同模拟;③在此技术框架成熟后,再进一步尝试从内部神经元层面解析模型的决策逻辑,探究更深层次的可解释性,最终构建兼具高适应性、强解释性的水动力预报模型体系。

参考文献:

[1] 中国气象局气候变化中心. 中国气候变化蓝皮书(2024)[M]. 北京:科学出版社,2024:2.
[2] 黄一为. 全国政协委员仲志余:加强城市极端暴雨洪水有效精准防控[N]. 中国水利报,2024-03-09(001).
[3] 陈朝晖,李鹏,张煜洲,等. 耦合一二维水动力模型的城市社区暴雨内涝模拟研究[J]. 水利水电技术(中英文),2024,55(7):55-69. (Chen Zhaohui, Li Peng, Zhang Yuzhou, et al. Urban community stormwater inundation simulation research on coupling one-and two-dimensional hydrodynamic models[J]. Water Resources and Hydropower Engineering, 2024, 55(7): 55-69. (in Chinese))
[4] 彭锋,柴福鑫,张红萍,等. 复杂地形的城市地表二维水动力模拟方法[C]//第五届城市水安全与水管理学术研讨会暨第六届城市防洪排涝学术研讨会论文集. 北京:中国水利水电科学研究院,2022:6.
[5] 卢兴超,徐宗学,李永坤,等. 基于 SWMM 与 LISFLOOD-FP 耦合模型的城市街区内部涝模拟研究[J]. 水资源保护,2024,40(3):98-105. (Lu Xingchao, Xu Zongxue, Li Yongkun, et al. Research on urban block waterlogging simulation based on coupling model of SWMM and LISFLOOD-FP [J]. Water Resources Protection, 2024, 40(3): 98-105. (in Chinese))

[6] 廖如婷,徐宗学,叶陈雷,等. 基于 SWMM 和 InfoWorks ICM 模型的大红门排水区暴雨内涝模拟[J]. 水资源保护,2023,39(3):109-117. (Liao Ruting,Xu Zongxue,Ye Chenlei,et al. Simulation of rainstorm waterlogging in Dahongmen Drainage Area based on SWMM and InfoWorks ICM models[J]. Water Resources Protection,2023,39(3):109-117. (in Chinese))

[7] 李致家. 现代水文模拟与预报技术[M]. 南京:河海大学出版社,2021.

[8] 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.

[9] 庄潇然,刘梅,蔡凝昊,等. 基于深度学习的降水临近预报方法及其在 2023 年江苏汛期的应用评估[J]. 暴雨灾害,2025,44(1):1-8. (Zhuang Xiaoran,Liu Mei,Cai Ninghao,et al. Evaluation of deep learning-based precipitation nowcasting methods during the 2023 flood season in Jiangsu Province[J]. Torrential Rain and Disasters,2025,44(1):1-8. (in Chinese))

[10] 纪守领,李进锋,杜天宇,等. 机器学习模型可解释性方法、应用与安全研究综述[J]. 计算机研究与发展,2019,56(10):2071-2096. (Ji Shouling, Li Jinfeng, Du Tianyu, et al. Survey on techniques, applications and security of machine learning interpretability[J]. Journal of Computer Research and Development,2019,56(10):2071-2096. (in Chinese))

[11] 夏弘. 深度学习和水动力学模型结合的中小河流洪水预报研究[D]. 济南:山东大学,2022.

[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] Yang Fang,Ding Wu,Zhao Lixiang, et al. Rapid urban flood inundation forecasting using a physics-informed deep learning approach[J]. Journal of Hydrology,2024,643:131998.

[14] Sebastian B,Alexander B,Grégoire M,et al. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation[J]. PloS one,2015,10(7):0130140.

[15] Kratzert F,Klotz D,Brenner C,et al. Rainfall-runoff modelling using long short-term memory (LSTM) networks[J]. Hydrology and Earth System Sciences,2018,22(11):6005-6022.

[16] Samek W, Montavon G, Vedaldi A, et al. Explainable AI: interpreting, explaining and visualizing deep learning[M]. Cham: Springer, 2019.

[17] Ahmed M A A,Deo R C,Feng Qi,et al. Deep learning hybrid model with Boruta-random forest optimiser algorithm for streamflow forecasting with climate mode indices, rainfall, and periodicity[J]. Journal of Hydrology,2021,599:126350.

[18] 吴剑. 基于长短时记忆网络的山丘区中小河流洪水预报研究[D]. 大连:大连理工大学,2021.

[19] 王雨洁,李致家,姚成,等. 基于分布式水文水动力耦合模型的秦淮河流域洪水模拟[J]. 河海大学学报(自然科学版),2025,53(2):11-18. (Wang Yujie,Li Zhijia,Yao Cheng,et al. Flood simulation in the Qinhuai River Basin based on a coupled distributed hydrological and hydrodynamic model[J]. Journal of Hohai University (Natural Sciences),2025,53(2):11-18. (in Chinese))

[20] 汪昊燃,王容,黄鹏年,等. 水文水力学结合的秦淮河流域洪水模拟与实时校正[J]. 河海大学学报(自然科学版),2023,51(3):25-304. (Wang Haoran,Wang Rong,Huang Pengnian,et al. Research on flood simulation and real-time correction of Qinhuai River Basin combined with hydrology and hydraulics[J]. Journal of Hohai University (Natural Sciences),2023,51(3):25-30. (in Chinese))

[21] 韩龙喜. 求解守恒形式的二维浅水方程的 SIMPLE 类程式[J]. 水利学报,2000,31(7):91-95. (Han Longxi. Solution for conservative equation of 2-D shallow flow by using revised SIMPLE algorithm[J]. Journal of Hydraulic Engineering,2000,31(7):91-95. (in Chinese))

[22] 赵棣华,戚晨,庾维德,等. 平面二维水流-水质有限体积法及黎曼近似解模型[J]. 水科学进展,2000,11(4):368-374. (Zhao Dihua,Qi Chen,Yu Weide,et al. Finite volume method and riemann solver for depth-averaged two-dimensional flow-pollutants coupled model[J]. Advances in Water Science, 2000, 11(4): 368-374. (in Chinese))

[23] Calders T,Esposito F,Hüllermeier E,et al. Machine learning and knowledge discovery in databases[M]. Berlin:Springer, ,2014:44848.

[24] 周恒安,成乐,施克权,等. 基于多任务图神经网络的非定常流体预测[J]. 科学技术与工程,2024,24(27):11733-11740. (Zhou Heng'an,Cheng Le,Shi Kequan,et al. Unsteady fluid prediction based on multi-task graph neural network[J]. Science Technology and Engineering,2024,24(27):11733-11740. (in Chinese))

[25] 孟涵,姚成,郑爱民,等. 不同情景下 LSTM 及其变体模型的洪水模拟研究[J]. 中国农村水利水电, 2025(2):114-120. (Meng Han,Yao Cheng,Zheng Aimin,et al. Flood simulation of LSTM and its variant models under different scenarios[J]. China Rural Water and Hydropower,2025(2):114-120. (in Chinese))

[26] 吕红燕,冯倩. 随机森林算法研究综述[J]. 河北省科学院学报,2019,36(3):37-41. (Lyu Hongyan,Feng Qian. A review of

random forests algorithm[J]. Journal of Hebei Academy of Sciences,2019,36(3):37-41. (in Chinese))

[27] 刘娟,彭剑虹,曹伟,等. 县域城市质量效益指数与城市综合竞争力相关性研究:基于斯皮尔曼秩相关系数的实证分析[J]. 质量与认证,2024,(12):63-65. (Liu Juan, Peng Jianhong, Cao Wei, et al. Correlation study between the quality and benefit index of county-level cities and the comprehensive competitiveness of cities[J]. China Quality Certification, 2024, 12(12):63-65. (in Chinese))

[28] 代硕,苏怀智,谷宇,等. 基于 PCA-GO-BP-AdaBoost 的大坝变形监控模型[J]. 人民黄河,2025,47(增刊 1):100-102. (Dai Shuo, Su Huaizhi, Gu Yu, et al. Dam deformation monitoring model based on PCA-GO-BP-AdaBoost[J]. Yellow River, 2025, 47(S1):100-102. (in Chinese))

[29] 胡嘉玮,徐宗学,陈浩,等. 基于精细化 GDP 格局的城市洪涝风险评估:以济南市黄台桥流域为例[J]. 南水北调与水利科技(中英文),2025,23(6):1480-1490. (Hu Jiawei, Xu Zongxue, Chen Hao, et al. Urban flood risk assessment based on refined GDP spatial distribution: a case study of Huangtaiqiao River Basin, Jinan City[J]. South-to-North Water Transfers and Water Science & Technology, 2025, 23(6):1480-1490. (in Chinese))

[30] 王双涛. 基于非结构化网格的 1D-2D 水动力模型耦合研究及应用[D]. 西安:长安大学,2023.

[31] 李致家,姚成,章玉霞,等. 栅格型新安江模型的研究[J]. 水力发电学报,2009,28(2):25-34. (Li Zhijia, Yao Cheng, Zhang Yuxia, et al. Study on Grid-based Xin' anjiang Model[J]. Journal of Hydroelectric Engineering, 2009, 28(2):25-34. (in Chinese))

[32] 化盈盈,张岱墀,葛仕明. 深度学习模型可解释性的研究进展[J]. 信息安全学报,2020,5(3):1-12. (Hua Yingying, Zhang Daichi, Ge Shiming, et al. Research progress in the interpretability of deep learning models[J]. Journal of Cyber Security, 2020, 5(3):1-12. (in Chinese))

(收稿日期:2025-05-18 编辑:熊水斌)

+++++
(上接第 68 页)

[20] 姚成,李致家,张珂,等. 基于栅格型新安江模型的中小河流精细化洪水预报[J]. 河海大学学报(自然科学版),2021,49(1):19-25. (Yao Cheng, Li Zhijia, Zhang Ke, et al. Fine-scale flood forecasting for small and medium-sized rivers based on Grid-Xin' anjiang model[J]. Journal of Hohai University(Natural Sciences), 2021, 49(1):19-25. (in Chinese))

[21] 童冰星,李致家,姚成. 基于 SoilGrids 的栅格新安江模型参数空间分布估算[J]. 水科学进展,2022,33(2):219-226. (Tong Bingxing, Li Zhijia, Yao Cheng. Estimation of distributed Grid-Xin' anjiang Model parameters based on SoilGrids[J]. Advances in Water Science, 2022, 33(2):219-226. (in chinese))

[22] Zhang Xiao, Liu Liangyun, Wu Changshan, et al. Development of a global 30 m impervious surface map using multisource and multitemporal remote sensing datasets with the Google Earth Engine platform[J]. Earth System Science Data, 2020, 12(3):1625-1648.

[23] 林祚顶,李兰涛. 海河“23·7”流域性特大暴雨洪水水文测报成效、存在问题及对策[J]. 中国水利,2023(18):5-8. (Lin Zuoding, Li Lantao. Results, problems and mitigation measures of hydrological monitoring and forecasting of “July 23” rainstorm and severe flood in the Haihe River Basin[J]. China Water Resources, 2023(18):5-8. (in Chinese))

[24] 赵人俊,王佩兰. 新安江模型参数的分析[J]. 水文,1988(6):2-9. (Zhao Renjun, Wang Peilan. Analysis of the parameters of the Xinanjiang model[J]. Journal of China Hydrology, 1988(6):2-9. (in Chinese))

[25] 石朋,丁松,司伟,等. 新安江模型敏感参数动态变化规律研究[J]. 河海大学学报(自然科学版),2024,52(3):1-6. (Shi Peng, Ding Song, Si Wei, et al. Study on dynamic variations of sensitive parameters in Xin' anjiang model[J]. Journal of Hohai University (Natural Sciences), 2024, 52(3):1-6. (in Chinese))

[26] 司伟,黄思琦,王培霞,等. 富春江水库流域径流变化及其量化归因分析[J]. 河海大学学报(自然科学版),2025,53(3):1-7. (Si Wei, Huang Siqi, Wang Peixia, et al. Analysis of runoff evolution in Fuchunjiang Reservoir Basin and its quantitative attribution[J]. Journal of Hohai University (Natural Sciences), 2025, 53(3):1-7. (in Chinese))

[27] 韩慧敏. 基于集成学习方法的 CLDAS 土壤湿度降尺度及其干旱监测应用:以华北地区为例[D]. 南京:南京信息工程大学,2022.

[28] 孔月,张珂,申晓骥,等. 基于微波遥感和多模型集成的安徽省土壤湿度反演[J]. 河海大学学报(自然科学版),2025,53(6):75-81. (Kong Yue, Zhang Ke, Shen Xiaoji, et al. Soil moisture inversion in Anhui Province based on microwave remote sensing and multi-model ensemble[J]. Journal of Hohai University (Natural Sciences), 2025, 53(6):75-81. (in Chinese))

(收稿日期:2025-04-23 编辑:熊水斌)