

DOI:10.19853/j.zgjsps.1000-4602.2024.17.020

基于时空特征融合的城市洪涝混合深度学习预测

司徒祖祥, 冯婉恩, 钟琪升, 廖晓婷, 饶开昕, 张佳博, 周倩倩
(广东工业大学 土木与交通工程学院, 广东 广州 510006)

摘要: 传统物理模型在二维地表淹没计算中虽然实现了高精度的求解,但其构建过程复杂、校准难度高,且计算效率低,在实时洪涝预报方面存在局限性。深度学习作为人工智能领域的重要分支,具有强大的数据处理和学习能力,可为洪涝预测提供变革性、创新性的技术手段。为此,提出了一种基于时空特征融合技术的城市洪涝混合深度学习预测模型,充分结合卷积神经网络和循环神经网络对空间和时间数据的学习优势,建立了SegNet-GRU混合模型。该模型能够准确预测研究区域在不同降雨情景下的极值水深和地表积水演变过程,实现了良好的预测精度(平均绝对误差、均方根误差、纳什效率系数和克林-古普塔效率系数分别为0.008 5、0.030 6、0.962 7、0.694 9)和处理速度(较一、二维模型预测速率提升近160倍)。

关键词: 城市洪涝预测; 时空特征融合; 深度学习; 混合模型

中图分类号: TU992 **文献标识码:** A **文章编号:** 1000-4602(2024)17-0131-06

Urban Flood Prediction Using Hybrid Deep Learning Model Based on Spatio-temporal Feature Fusion

SITU Zu-xiang, FENG Wan-en, ZHONG Qi-sheng, LIAO Xiao-ting, RAO Kai-xin,
ZHANG Jia-bo, ZHOU Qian-qian

(School of Civil and Transportation Engineering, Guangdong University of Technology,
Guangzhou 510006, China)

Abstract: The traditional physical models, while capable of accurately solving two-dimensional surface inundation calculations, are hindered by a complex construction process, high calibration difficulty, and low calculation efficiency. These limitations impede real-time flood prediction. As a crucial subset of artificial intelligence, deep learning has robust data processing and learning capabilities, offering a transformative and innovative technical approach for flood prediction. Consequently, a hybrid deep learning model for urban flood prediction was proposed based on spatio-temporal feature fusion technology. The SegNet-GRU hybrid model was developed by fully integrating the advantages of convolutional neural network and recurrent neural network in learning spatial and temporal data. The model demonstrated high accuracy in predicting the evolution process of the maximum water depth and surface water ponding under varying rainfall scenarios within the study area, with good prediction accuracy (mean absolute error, root-mean-square error, Nash-Sutcliffe efficiency coefficient, and

基金项目: 广东省自然科学基金资助青年提升项目(2023A1515030126); 广东省自然科学基金资助面上项目(2024A1515011791)

通信作者: 周倩倩 E-mail: qiaz@foxmail.com

Klin-Gupta efficiency coefficient at 0.008 5, 0.030 6, 0.962 7 and 0.694 9 respectively) as well as significantly improved processing speed (nearly 160 times faster than one- and two-dimensional models).

Key words: urban flood prediction; spatio-temporal feature fusion; deep learning; hybrid model

在气候变化和城市化进程的影响下,城市内涝灾害频发,不仅给城市正常运行和居民生活带来不便,也对人民群众的生命财产安全造成了严重威胁^[1]。通过专业仿真模拟技术支撑洪涝管理,可提升决策者对城市洪涝影响的预测、分析和管理能力,减轻其对社会和环境的不利影响^[2]。传统洪涝预测主要基于物理驱动模型,通过模拟地下一维管流、地上二维以及双层系统耦合的方式,对径流通路和淹没区域进行水文水动力的计算^[3]。尽管物理模型可以精准模拟洪涝过程,但其构建过程需要依赖大量的数据支撑和繁琐的建模步骤,计算效率低且容易出现求解不稳定的情况,在大规模计算和实时预报方面存在明显局限^[4]。

作为人工智能的重要分支,近年来发展迅速的深度学习技术为洪涝预测提供了一种创新性方案,在水文水资源方面得到进一步探索。崔忠捷等^[5]提出了数据挖掘-长短期记忆(DM-LSTM)耦合模型,用于模拟重庆悦来生态城的降雨径流模式;李步等^[6]研究发现,LSTM模型在黄河源区径流模拟中的性能优于物理水文模型THREW;崔震等^[7]建立了长短期记忆-编码解码(LSTM-ED)深度学习模型,用于三峡水库短时预见期的入库洪水预报。尽管深度学习在一维水文预测领域已有一些优异表现,但在城市二维洪涝预测方面的研究较少。深度学习可有效提取复杂数据特征,通过分析数据间隐藏的非线性关系,实现多任务多维度预测,具有高精度和低计算成本等优势^[8]。笔者提出了一种基于时空特征融合的城市洪涝混合深度学习预测方法,充分结合卷积神经网络(CNN)和循环神经网络(RNN)的优势,实现对城市洪涝过程静态和动态的预测。

1 城市洪涝混合深度学习预测模型

1.1 卷积神经网络——SegNet

卷积神经网络是一类包含卷积计算和深度结构的前馈神经网络,被广泛用于计算机视觉图像分析。典型CNN由一系列隐藏层组成:①卷积层,使用卷积核对输入数据进行卷积运算,提取特征;②

池化层,对卷积层输出的特征图进行降采样,减少数据大小和计算量,同时泛化特征的存在;③批量归一化层,通过调整和缩放,将前一层的激活归一化为标准正态分布,加速收敛并提高泛化性能;④激活函数层,对输入特征进行非线性变换;⑤全连接层,将特征处理为扁平化矩阵,实现分类或回归任务。通过这些层及其功能,CNN可实现高效的特征提取,因此擅长处理大数量的空间特征数据。

SegNet是一种基于CNN的语义分割网络,能够将输入图像中的每个像素栅格分类为不同的属性类别。SegNet使用编码器-解码器结构,能够将高维特征的分辨率恢复至原始图像大小,用于洪水预测中空间数据特征的学习。SegNet的编码器由8个卷积层组成,每层各对应1个解码层,见图1。卷积层采用批量归一化和ReLU激活函数,后接一个最大池化层,以逐步减小特征图的分辨率。解码器采用卷积层、批量归一化、ReLU激活函数和上采样层,逐步恢复特征图的分辨率。此外,SegNet引入了“跳跃连接”机制,将编码器的特征图连接到解码器的相应位置,解决了学习过程中可能出现的细节和精度缺失问题。由于SegNet的特殊设计,模型既可实现高精度预测,又可减少内存需求和计算时间。




图1 SegNet的网络结构

Fig.1 Network structure of SegNet

1.2 循环神经网络——门控循环单元网络(GRU)

循环神经网络是前馈神经网络的一种变体,擅长处理与时间序列相关的问题,且允许管理不同长度的序列输入。典型RNN由多个隐藏层组成:①循环层,用于捕捉序列数据的时间依赖性,层中的循

环单元将接收前一时刻的隐藏状态作为输入,同时输出当前时刻的隐藏状态;②激活函数层,控制序列信息的流动,增加模型的非线性表达能力;③全连接层,对输入进行处理并生成相应的特征图;④重塑层,将输出的尺寸重新排列,以获得新的向量表示。RNN考虑过往信息对生成输出的影响,解决了时间依赖性的学习问题,近年来在水文预测方面的应用效果尤其显著^[9-10]。

GRU是一种改进的RNN架构,在简单RNN的基础上对网络结构进行调整,加入门控机制以控制网络中的信息传递。在洪水序列的网络拓扑聚合建模中,GRU可提取序列的时间特征并完成预测任务。GRU网络只包含两个门,即更新门和重置门(见图2),这不仅简化了网络设计,而且有效防止过拟合的发生,提高模型性能。更新门 z_t 用于控制前一时刻的状态信息 h_{t-1} 被带入当前状态 h_t 的程度。更新门的值越大,前一时刻的状态信息被带入的程度就越大。根据时间序列输入 x_t ,重置门 r_t 控制前一时刻的状态信息 h_{t-1} 有多少被写入当前的候选集合 \tilde{h}_t ,即前一状态写入的信息数量与重置门有关。

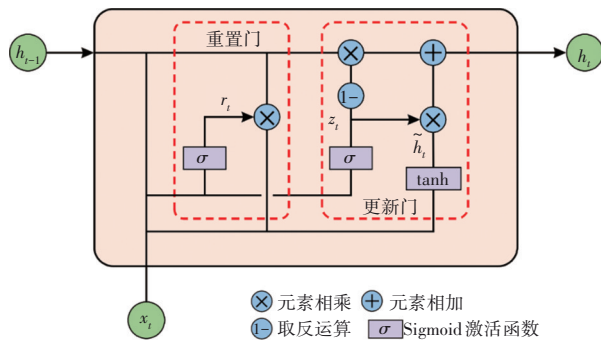


图2 GRU的单元结构

Fig.2 Unit structure of GRU

1.3 SegNet-GRU混合预测模型

SegNet-GRU网络(见图3)的创新之处在于实现了空间和时间数据特征的融合,允许多类型、多维度数据的处理和学习,分为两个阶段:①空间和时间数据特征由SegNet和GRU分别进行处理。GRU网络由两个GRU单元组成,用于识别序列数据中的时间特征,如不同降雨强度的时间变化;SegNet识别空间特征,如高程、流向和不透水性等,这些空间数据通过预处理合成一张多通道图像,随后输入SegNet中提取关键特征信息(如洪水易发区域)。②经GRU处理后的时间数据,与SegNet输出的空间数

据结合,整体进行分析,并预测输出像素级别的图像分类结果,即洪涝指标结果(如极值水深)。




图3 SegNet-GRU混合模型结构

Fig.3 Structure of SegNet-GRU hybrid model

2 案例分析

2.1 研究区域数据

采用我国北部H市作为研究区域,该区域位于华北北部,年均降雨量约为396 mm,降雨主要集中在7月和8月。时间特征数据包含90场降雨事件,模拟不同降雨强度下的积水深度。降雨输入依据《城市暴雨强度公式编制和设计暴雨雨型确定技术导则》和区域暴雨强度公式,采用芝加哥雨型法计算和生成具体暴雨,如式(1)所示。

$$q = 635 \times \frac{1 + 0.841 \times \lg P}{t^{0.61}} \quad (1)$$

式中: q 为暴雨强度, $L/(h \cdot s)$; P 为设计重现期,年; t 为降雨历时,min。设计重现期选取1~100年,降雨历时包括2、4和6 h,统一采用10 min间隔进行模拟。

空间特征数据包括7个洪涝驱动因子,分别为DEM(高程)、ASP(流向)、SDEPTH(水深)、TWI(地形湿度指数)、IMP(不透水性)、FLIMP和PIPE(管道)。DEM定义为每个栅格单元的地形高程;ASP表示每个栅格单元的水流方向,即地表高程的变化率;SDEPTH表示研究区域的地形水槽深度,计算方法为水槽出口点的高程与地形高程之差;TWI表征研究区域地形对径流流向和蓄水量的影响,反映流域地表水的排水情况;IMP定义为每个栅格单元的不透水性程度,影响产生的径流量,本研究将建筑物和道路的不透水性定义为100%;FLIMP定义为给定栅格单元上游的总不透水面积,通过使用该单元格内不透水性对流量积累计算结果进行加权计算;PIPE表示研究区域的管道布设情况,即区域管网的铺设密度和体积,反映区域排水能力。

由于缺乏准确的历史数据来描述积水范围和

水深,本研究采用一、二维耦合水动力模型来求解不同降雨情景下的淹没水深和过程。水动力模型的输入数据包括降雨数据、管网系统参数(如:汇水区属性、节点和管道参数)、地面数字高程模型,输出的结果为模拟降雨情景下的淹没范围和水深。

2.2 模型设置

在深度学习模型构建中,90%的洪涝模拟数据用于模型训练,其余10%用于测试模型性能。混合模型在MATLAB平台完成训练和测试。训练采用Adam优化器,其中动量参数 β_1 和 β_2 分别设置为0.9和0.999。初始学习率设为0.01,批处理大小设为8,总训练迭代次数为100次。混合模型的训练损失函数采用MSE(均方误差),同时确保在评估损失函数时排除图像中没有水深数据的像素。实验环境为Windows 10操作系统,配备Intel Xeon E5-2690 v4型CPU和NVIDIA Quadro P5000型GPU,以及64 GB的运行内存。

2.3 模型评价指标

采用预测精度和计算时间两类指标对模型进行评价,其中预测精度反映了模型预测值与观测值之间的差异程度,采用MAE(平均绝对误差)、RMSE(均方根误差)、NSE(纳什效率系数)和KGE(克林-古普塔效率系数)进行表征,如式(2)~(5)所示。其中,MAE和RMSE衡量模型预测误差的大小,NSE和KGE综合分析模型的积水预测效果,前者越接近0、后者越接近1,说明预测结果越可靠。计算时间是指预测一张洪涝输出图所需要的时间,单位为s。

$$MAE = \frac{1}{n} \sum_{i=1}^n |Q_{obs} - Q_{sim}| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |Q_{obs} - Q_{sim}|^2} \quad (3)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{sim})^2}{\sum_{i=1}^n (Q_{obs} - \overline{Q_{obs}})^2} \quad (4)$$

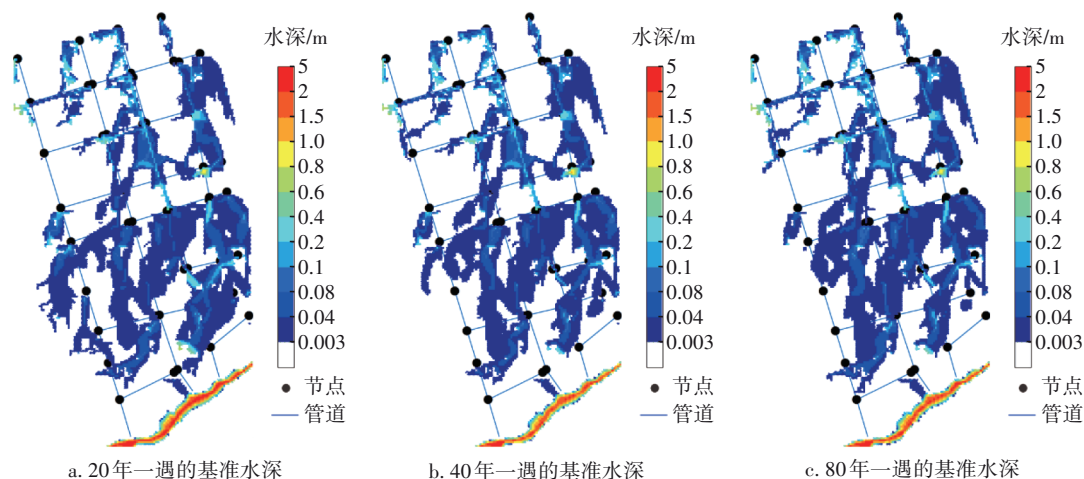
$$KGE = 1 - \sqrt{(r-1)^2 + (\alpha-1)^2 + (\beta-1)^2} \quad (5)$$

式中: n 为计算样本数; Q_{obs} 和 Q_{sim} 分别为观测值和预测值; $\overline{Q_{obs}}$ 为观测数据的平均值; r 为皮尔逊相关系数; α 为平均模拟水深与平均观测水深之比; β 为偏差。

3 结果与讨论

模型的预测精度指标MAE=0.008 5、RMSE=0.030 6、NSE=0.962 7、KGE=0.694 9。其中,MAE和RMSE趋近0,说明模型能够准确预测区域内大部分栅格单元的积水深度,预测结果与物理模型的计算结果无显著偏差;NSE趋近1,进一步验证了模型在洪涝预测方面的准确性和有效性;由于研究区域的复杂性和差异性,KGE接近0.7,表明模型依然具有较好的预测能力。另外,混合模型的计算时间仅为0.968 s,较一、二维耦合水动力模型的计算时间(153.2 s)提升近160倍,满足实时预测要求。

在视觉效果方面,图4对比了重现期为20、40和80年一遇降雨情景下,水动力模型的模拟水深(即作为基准水深)和混合模型的预测水深。3种重现期的选择是基于以往的水文学研究和实践经验^[11-12],能够代表不同程度的极端降雨事件影响,既涵盖了一定的极端性,又考虑了常见的暴雨情景,满足大部分地区和工程项目的需求。



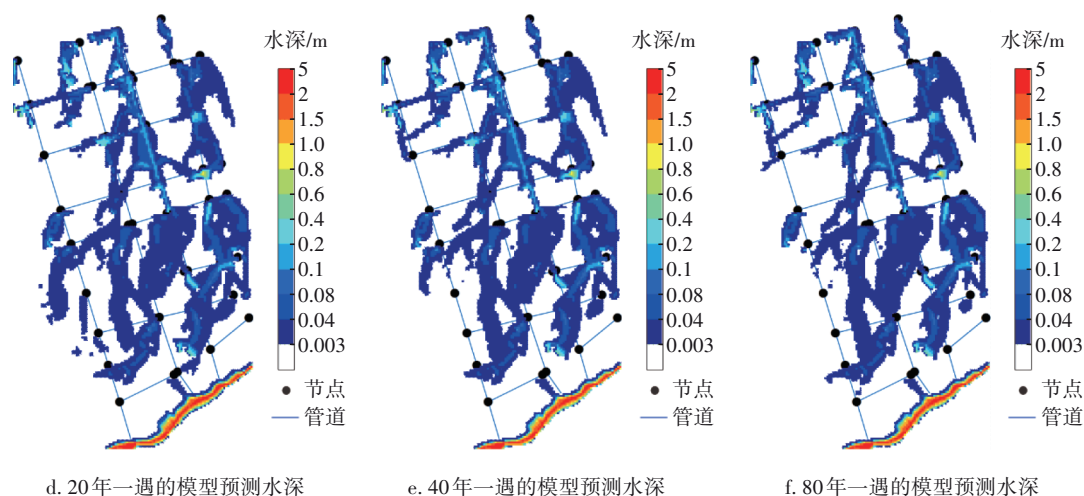


图4 重现期为20、40和80年一遇降雨情景下基准水深和模型预测水深的对比

Fig.4 Comparison of baseline and model predicted water depth for rainfall scenarios with 20-, 40- and 80-year return periods

图4的结果表明,模型在不同降雨强度下,均能成功预测地表洪涝的淹没深度和空间分布。模型整体表现良好,除了水体附近的一些小区域,混合模型能够准确识别出区域内的地表流通过程和局部洼地。

图5从数学统计的角度分析了所有重现期下预测水深与实际水深之间的相关性。可以看出,绝大部分的积水深度集中在2 m以内,对于这部分水深,模型的预测结果与实际情况基本一致,不存在预测偏差(高估或低估)。在靠近河流和溪流区域,部分水深超过2 m,此时模型的预测精度有所下降,预测水深高于实际值,但误判程度不高。总体而言,混合模型可以很好地预测大部分地区的水深,呈现出理想的预测效果。




图5 所有重现期下预测水深和实际水深的相关性

Fig.5 Correlation between predicted and real water depth for all return periods

4 结论

提出了一种基于时空特征融合技术的混合深度学习模型SegNet-GRU,充分结合CNN和RNN对空间和时间数据的学习优势,实现高精度、高效率的城市洪涝预测。该模型允许不同时间维度序列的输入,同时可以处理空间数据特征。研究结果表明,SegNet-GRU具有良好的预测精度和处理速度。在多种降雨情景下模型预测水深与实际水深一致性较高,整体预测性能良好。

本研究仍然存在一些局限性有待解决。首先,用于训练验证的实际水深通过水动力模型得到,而非现场调研数据。未来将计划与企业或政府合作,通过布设监测设备(如传感器)收集实际的降雨和洪涝数据,进一步验证和改进模型。其次,计划将混合模型整合到城市洪涝预警预报系统进行测试和修正,提升对城市洪涝影响的快速评估和响应能力。

参考文献:

- [1] 赵超辉, 王金红, 张云霞, 等. 城市内涝特征、成因及应对研究综述[J]. 灾害学, 2023, 38(1): 220-228.
ZHAO Chao-hui, WAN Jin-hong, ZHANG Yun-xia, et al. Review of the characteristics, causes and governance of urban flood in China [J]. Journal of Catastrophology, 2023, 38(1): 220-228 (in Chinese).
- [2] 张凡. 中小河流洪水预报的难点与解决方案[J]. 科技资讯, 2018, 16(30): 117-119.
ZHANG Fan. Difficulties and solutions for small and

- medium-sized river flood forecasting [J]. Science & Technology Information, 2018, 16(30): 117-119 (in Chinese).
- [3] 周倩倩, 苏炯恒, 梅胜, 等. 1D/1D及1D/2D耦合水动力模型构建方法研究[J]. 水资源与水工程学报, 2019, 30(5): 21-25.
- ZHOU Qianqian, SU Jiongheng, MEI Sheng, *et al.* Research on coupled 1D/1D and 1D/2D hydrodynamic model construction method [J]. Journal of Water Resources & Water Engineering, 2019, 30(5): 21-25 (in Chinese).
- [4] 彭伟, 熊佳艺, 江显群, 等. 基于神经网络的小型水库洪水预报研究[J]. 人民珠江, 2023, 44(3): 1-8.
- PENG Wei, XIONG Jiayi, JIANG Xianqun, *et al.* Flood forecasting for small reservoirs based on neural networks [J]. Pearl River, 2023, 44(3): 1-8 (in Chinese).
- [5] 崔忠捷, 卿晓霞, 杨森雄. 基于DM-LSTM的城市降雨径流预测研究[J]. 中国给水排水, 2022, 38(19): 132-138.
- CUI Zhongjie, QING Xiaoxia, YANG Senxiong. Prediction of urban rainfall runoff based on DM-LSTM [J]. China Water & Wastewater, 2022, 38(19): 132-138 (in Chinese).
- [6] 李步, 田富强, 李钰坤, 等. 融合气象要素时空特征的深度学习水文模型[J]. 水科学进展, 2022, 33(6): 904-913.
- LI Bu, TIAN Fuqiang, LI Yukun, *et al.* Development of a spatiotemporal deep-learning-based hydrological model [J]. Advances in Water Science, 2022, 33(6): 904-913 (in Chinese).
- [7] 崔震, 郭生练, 汪芸, 等. 三峡入库洪水概率预报的深度学习模型[J]. 水力发电学报, 2023, 42(4): 1-10.
- CUI Zhen, GUO Shenglian, WANG Yun, *et al.* Deep learning model for probability forecasting of flood to Three Gorges Reservoir [J]. Journal of Hydroelectric Engineering, 2023, 42(4): 1-10 (in Chinese).
- [8] 李大洋, 姚轶, 梁忠民, 等. 基于变分贝叶斯深度学习的水文概率预报方法[J]. 水科学进展, 2023, 34(1): 33-41.
- LI Dayang, YAO Yi, LIANG Zhongmin, *et al.* Probabilistic hydrological forecasting based on variational Bayesian deep learning [J]. Advances in Water Science, 2023, 34(1): 33-41 (in Chinese).
- [9] GAO S, HUANG Y, ZHANG S, *et al.* Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation [J]. Journal of Hydrology, 2020, 589: 125188.
- [10] CHO M, KIM C, JUNG K, *et al.* Water level prediction model applying a long short-term memory (LSTM)-gated recurrent unit (GRU) method for flood prediction [J]. Water, 2022, 14(14): 2221.
- [11] 鲁佳慧, 刘家宏, 刘创, 等. 深圳市洪涝风险量化评估与损失预测[J]. 水电能源科学, 2021, 39(12): 73-75.
- LU Jiahui, LIU Jiahong, LIU Chuang, *et al.* Flood risk quantitative assessment and loss forecast in Shenzhen City [J]. Water Resources and Power, 2021, 39(12): 73-75 (in Chinese).
- [12] 潘鑫鑫, 侯精明, 陈光照, 等. 基于K近邻和水动力模型的城市内涝快速预报[J]. 水资源保护, 2023, 39(3): 91-100.
- PAN Xinxin, HOU Jingming, CHEN Guangzhao, *et al.* Rapid forecasting of urban waterlogging based on K-nearest neighbor and hydrodynamic model [J]. Water Resources Protection, 2023, 39(3): 91-100 (in Chinese).

作者简介: 司徒祖祥(1999—), 男, 广东开平人, 硕士研究生, 研究方向为城市洪涝风险评估。

E-mail: zxsitu@sina.com

收稿日期: 2024-01-23

修回日期: 2024-03-01

(编辑: 刘贵春)