

喻谦花, 霍继超, 仝妍彦. 基于支持向量机的开封市内涝评估模型研究[J]. 灾害学, 2023, 38(3): 87–91, 99. [YU Qianhua, HUO Jichao, TONG Yanyan. Research on Waterlogging Evaluation Model of Kaifeng Based on Support Vector Machine [J]. Journal of Catastrophology, 2023, 38(3): 87–91, 99. doi: 10.3969/j.issn.1000–811X.2023.03.014.]

基于支持向量机的开封市内涝评估模型研究^{*}

喻谦花^{1,2}, 霍继超^{1,2}, 仝妍彦^{1,2}

(1. 中国气象局 河南省农业气象保障与应用技术重点实验室, 河南 郑州 450003; 2. 开封市气象局, 河南 开封 475004)

摘要: 以内涝典型易发区河南省开封市主城区为例, 利用城市内涝监测点逐小时积水深度和同时段气象站降雨资料, 应用灰色关联度和支持向量机方法, 构建基于降水因子(模型1组)和历史积水+降水因子(模型2组)的内涝评估模型; 并以2021年“7·20”特大暴雨过程为例, 对模型适用性进行评价。结果表明: 1~3 h短时强降水是内涝灾害形成的主要原因, 积水与暴雨发生的时间相比, 具有滞后1~3 h的特点; 模型1组对内涝风险有一定评估能力, 但总体误差明显高于模型2组; 模型2组有80%的站点 $R^2 \geq 0.9$, 训练集和测试集的平均 $MAE \leq 3.9$ cm, 拟合结果评价优秀, 并具有较好的泛化能力。在开封市2021年“7.20”极端暴雨过程中, 模型2组评估结果与实测积水的平均 $RSME$ 为4.33 cm, 平均 MAE 为2.94 cm, 较为准确地评估了极端暴雨过程内涝灾害的涨水期、退水期和最大积水深度, 能够为城市防汛和应急决策提供较好的支撑。

关键词: 城市内涝评估; 支持向量机; “7·20”特大暴雨; 河南开封

中图分类号: P49; X915.5; X43 **文献标志码:** A **文章编号:** 1000–811X(2023)03–0087–06

doi: 10.3969/j.issn.1000–811X.2023.03.014

近年来, 城市暴雨内涝灾害频发, 由此带来的损失呈逐渐增加趋势, 已成为严重危害城市安全的主要气象灾害之一^[1]。许多城市深受洪水内涝灾害威胁^[2–5]。因此, 准确评估城市内涝风险、发布预警信息以及减少洪水灾害造成的损失是城市管理的重点^[6]。

数值模拟是研究暴雨内涝致灾机理、评估暴雨内涝风险的主要方法。这类模型主要包括 Mike Urban 和 SWMM 等。朱呈浩等^[7]以 SWMM 模型为基础, 建立了西安市沣西新城区洪涝过程模型, 分析排水管网中节点的溢流数量和严重程度, 模拟了地表积水深度的变化。胡彩虹等^[8]以郑州市为例, 构建了6种空间尺度的 SWMM 暴雨洪水模型, 并确定了当子汇水区平均面积为0.25 km²时, 最符合郑州市的实际洪涝情况。朱颖蕾等^[9]构建了 MIKE21 和 MIKE Urban 耦合模型, 对岳阳市的12种排涝情景进行模拟, 表明该模型在湖区平原城市具有较好的应用价值。但随着城市的快速发展, 城市近地表层变得更为复杂, 数值模拟为基础的模型对数据要求高, 模拟的计算效率低, 很难满足当前城市应急管理的需求。

近年来, 机器学习方法应用广泛。用于暴雨洪涝研究中的主要包括卷积神经网络(CNN), LSTM 长短记忆神经网络、BP 神经网络、Logistics 回归、PSO–ESN 等^[10–15], 能够显著缩短城市内涝风险的评估时间。但这些算法需要较高的计算能力和较多的训练样本, 当前大部分城市测得的内涝数据样本量不能满足深度学习的需求, 限制

了其在城市内涝风险评估中的应用。因此, 当前应用较为广泛的支持向量机算法, 其综合了统计学习、机器学习和神经网络等技术, 在解决小样本、非线性等问题中具有一定的优势, 适合应用于洪涝、径流量预报方面的研究。如梅松等^[16]基于支持向量机构建了福建沙县水文站流量预报模型, 获得较好的预报效果, 并认为该模型泛化能力强, 训练速度快, 有很强的应用前景。卢敏等^[17]将支持向量机应用于年径流量预报, 表明支持向量机方法预报结果略好于 BP 神经网络。在本研究中, 利用历史降水和积水数据, 尝试应用灰色关联法与支持向量构建内涝评估模型, 探讨该方法在城市内涝评估方面的应用能力和效果。

1 研究区域、基础数据来源和方法

1.1 研究区域背景

开封市位于黄河下游南岸, 河南省中东部, 113°51′51″~115°15′42″E, 34°11′43″~35°11′43″N, 总面积6444 km², 市区面积约546 km²^[18]。气候属暖温带大陆性季风气候, 年平均气温为15.2℃, 年平均降水量为615.3 mm, 降水主要集中在7—8月份。虽属华北平原, 但开封市主城区呈中部略低, 四周略高的盆地地形, 暴雨导致的积水主要靠泵站抽排。据本地城市管理局工作人员介绍, 当降雨量达到50 mm/h时, 积水需要6 h才能排完, 严重影响城市的防洪安全和居民出行。因此, 极有必要开展城市暴雨内涝评估技术研究。

* 收稿日期: 2023–01–29

修回日期: 2023–03–15

基金项目: 河南省科技研发计划联合基金项目(222103810095); 开封市重点(重大)科技计划项目(19ZD012)

第一作者简介: 喻谦花(1976–), 女, 汉族, 河南内乡人, 高级工程师, 从事灾害性天气机理及影响研究。

E-mail: Qfxy.y@163.com

表 1 开封市积水内涝自动监测站点位置

编号	地理位置	经度/(°)	纬度/(°)	对应气象站	与气象站的距离/km
1	市国家气象站	114.295	34.803	A 站	0.115
2	复兴大道西段	114.320	34.832	B 站	1.078
3	滨河路公园路交叉口	114.367	34.779	E 站	0.962
4	东京大道与西环北路交叉口	114.323	34.821	C 站	1.168
5	魏都路五一路口	114.333	34.776	D 站	1.083
6	西环城路与向阳路交叉口	114.324	34.795	D 站	1.353
7	大庆路与滨河路交叉口	114.324	34.785	D 站	1.164
8	复兴大道与东环北路交叉口	114.371	34.828	F 站	1.906
9	东环路与苹果园中路口	114.368	34.809	F 站	0.273
10	市第三职业高中大门对面	114.346	34.784	D 站	0.702

1.2 数据来源

根据开封市城区内发生内涝积水的程度,选择 10 个内涝自动监测站作为研究对象,以 1~10 数字为编号。数据收集时间分辨率为小时,经过筛选,共获取 1 200 个有效积水样本。开封市主城区内共有 6 个气象监测站,编号为 A~F。应用 ArcGIS 邻域分析工具,按照气象站位置创建泰森多边形,每个多边形区域内,对应 1~4 个积水监测站。由表 1 可以看出,气象站和内涝监测站距离多在 1 km 左右,部分站点小于 0.5 km,对应关系较为合理;仅有第 8 站距离 F 气象站稍远,为 1.906 km,但也明显小于气象站网空间分辨率(3~5 km),能够代表内涝监测第 8 站降雨情况。

1.3 支持向量机

支持向量机(SVM)建立在统计学习中的 VC 维理论和结构风险最小原理基础上^[19],它将具体问题转化为一个二次型寻优问题,较好地解决了小样本、非线性、高维数和局部极小点等实际问题^[20]。同时,支持向量机能以任意的精度逼近任意函数,并有较好的泛化能力^[17]。本文基于强降雨导致的内涝过程,应用支持向量机方法,构建各积水站点支持向量机回归内涝评估模型。

支持向量机基本原理,设训练样本集为 $D = \{(x_i, y_i), i=1, 2, \dots, N\}$, x_i 为自变量, y_i 为因变量, N 为样本总量。其回归函数(式 1)和结构风险函数(式 2)如下:

$$f(x) = (\omega, x) + b = \sum_{i=1}^n a_i K(x_i, x) + b; \quad (1)$$

$$R(f) = \frac{1}{2} \omega^2 + C \sum_{i=1}^n L_e[f(x_i) - y_i]。 \quad (2)$$

式中: $f(x)$ 为模型输出变量; ω 为特征空间权向量; a_i 为 Lagrange 乘子, $K(x_i, x)$ 为核函数, C 为惩罚因子, L_e 为不敏感损失函数。

本文中核函数使用了 Liner 和 Rbf, 其表达式如下:

$$K(x_i, x) = (x_i, x); \quad (3)$$

$$K(x_i, x) = \exp(-g \|x_i, x\|)(g > 0)。 \quad (4)$$

式中: g 为核函数的宽度因子。

1.4 灰色关联度

强降雨导致的内涝积水除有其自身的变化规律外,还受到降水时间序列的影响。灰色关联分析基于灰色关联度,它通过对数据序列几何关系和曲线几何形状的相似程度进行比较,分析各因素之间的关联程度^[20]。黄曦涛等^[21]利用灰色关联理论对降雨量和内涝导致的损失进行定量分析,表明降雨对经济、交通和商业影响较大。该方法弥补了数理统计需要大样本量、典型概率分布、计算量大的缺陷^[22],适用于本文中分析降水和历史积水对未来积水变化趋势的影响。具体计算步骤:

(1) 确定特征序列 $X_0 = (x_0(1), x_0(2), \dots$

$x_0(n))$; $X_i = (x_i(1), x_i(2), \dots, x_i(n))$ 为相关因素序列,即比较序列。

(2) 对数据进行标准化处理,计算各序列初值 $X'_i = X_i/x_{i0}$ 。

(3) 计算特征序列和比较序列的灰色关联系数:

$$\xi_{0i} = \frac{\min_k |x_0(k) - x_i(k)| + \rho \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_k |x_0(k) - x_i(k)|}。 \quad (5)$$

式中: ρ 为分辨系数,在(0, 1)内取值, $k=1, 2, \dots, n$ 。

(4) 计算关联度 $r_{0i} = \frac{1}{m} \sum_{k=1}^m \xi_{0i}(k)$, 并由大到小进行排序, r_i 值越接近 1, 关联性越好。

2 模型构建

2.1 暴雨和内涝特征

基于开封主城区不同方位的 10 个城市内涝站点监测的积水深度,统计 2020—2022 年最大积水深度超过 10 cm 的积涝过程,经过质控和预处理,共筛选出 12 个个例,得到 1 200 个积水样本,各站点样本数在 74~205 个,最大积水深度在 19~106 cm。基于 6 个城市气象站,统计内涝对应时段各气象站最大 1 h 累计降雨量在 42.2~103.4 mm,最大 3 h 累计降水量在 64.5~157 mm,最大 6 h 累计降水量在 73~173.5 mm。各个过程的 1 h 降水量占 6 h 总降水量 32%~100%,平均占 57.7%; 3 h 降水量占 6 h 总降水量的 63%~100%,平均占 83.1%(图 1)。综上所述,较强的内涝过程主要由 1~3 h 短时强降雨所致,内涝站点间最大积水差达 87 cm,各气象站 1~6 h 最大累计降水量差达 61.2~100.2 mm,区域性差异极为明显,有必要分区域分站点构建内涝评估模型。




图 1 开封市 2020—2022 年 12 次积涝过程 1~6 h 降水量

2.2 因子选取

将当前积水深度设为特征序列, 将其他因子设为比较序列, 分辨系数设为默认 0.5, 对积水站点数据集进行灰色关联度分析。结果表明, 积水深度和本时次 1 h 累计降水 ($R1$)、3 h 累计降水 ($R3$)、6 h 累计降水 ($R6$) 以及上一时次 1 h 累计降水量 ($R1_1$) 关联度都在 0.6 以上。与李海宏等^[23] 研究结果一致, 1 ~ 6 h 最大雨量与暴雨内涝灾情密切相关。进一步分析发现, 大部分站点的积水深度和上一时次 1 h 累计降水量 ($R1_1$) 的关联度高于当前时次 1 h 累计降水量, 有 3 个站点的积水深度与 3 h 和 6 h 累计降水量关联度高于 1 h 累计降水量因子, 说明积水与暴雨发生的时间相比, 具有滞后的特点, 与史军等^[5] 研究结果一致。由于积水自身还具有随时间变化的规律, 历史积水深度的变化能够在一定程度中表达地理信息、汇流、排水等环境情况。因此选取过去 1 h 和 2 h 整点积水深度 (W_1 , W_2) 加入数据集, 通过灰色关联度分析发现, 当前时次积水深度与前 1 ~ 2 h 的历史积水深度关联度达到 0.8 以上, 有 5 个站点达到 0.9 以上, 明显高于降水因子的关联度。

2.3 样本处理

(1) 数据质控。智能雷达水位计积水在线监测的数据, 灵敏度高, 容易受到干扰, 因此通过与同时期降水量对比、分钟级数据前后连续性检查, 对异常值进行处理和消空, 从而达到数据质控的目的。由于积水过程分为涨水期和退水期, 涨水期选取 1 h 内最大积水深度为该时次积水值, 退水期以整点积水深度为该时次积水值。降水数据取整点累计降水量。

(2) 样本标准化处理。标准化处理有利于避免各因子间量级的差异, 消除各个因子由于量纲和单位不同的影响, 本文对样本的自变量和因变量用 $\min - \max$ 方法进行标准化处理:

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

式中: y_i 为 $\min - \max$ 标准化处理过数值变量, x_i 为标准化前变量, x_{\max} 和 x_{\min} 分别为变量 x 的最大值和最小值。

2.4 模型训练及评价方法

将各站点数据集划分为训练集、验证集和测试集 3 部分。选取数据集的 7 成数据训练模型, 剩余部分为测试集, 用来测试模型泛化能力。同时通过 k 折 (本研究中, k 设为 3) 对模型的稳定性进行交叉验证, 将数据集划分为 k 个大小相似的互斥子集, 每次用 $k-1$ 个子集作为训练集, 剩下的 1 个子集作测试集, 进行 k 次训练和测试, 最后返回 k 个评估结果的均值, 避免由于数据集划分不合理而导致的在训练集上过拟合问题。为了避免数据分布不均衡造成的模型误差, 训练前对数据进行洗牌。支持向量机算法在实现过程中, 核函数的选择较为重要, 常见的核函数有 4 种, Linlinear 核、Rbf 核、Ploy 核和 Sigmoid 核。通过对比实验, 并利用 k 折交叉验证, 逐个循环进行核函数及超参数的确定, 将 Rbf 核或 Linlinear 核确定为本文中所研究的积水站点模型的核函数, 误差收敛条件使用了默认 0.001, 通过不断调整惩罚系数 C 和迭代次数, 从而获取更高精度的模型。

模型训练阶段, 通过 R^2 (拟合优度)、 $RMSE$ (均方根误差)、 MAE (平均绝对误差) 指标, 对模型进行效果评价。 R^2 越靠近 1, 模型准确度越高; $RMSE$ 的 MAE 取值越小, 模型准确度越高。

3 结果与分析

强降水是导致城市内涝灾害的主要原因。首先基于降水因子建立了的积涝评估模型 1 组。为了提高模型精度, 将 4 个降水因子全作为特征因子参与训练。经过多次试验和参数调整, 70% 的站点模型核函数使用 Rbf 核较 Linear 核有更好评估精度, 也说明降水的非线性特征明显。由表 2, 模型训练和测试结果中 1、3、5、7 和 9 站训练集和测试集 R^2 超过 0.5, 其中 1、3 站训练集和测试集 R^2 都超过 0.73, 有一定的应用价值。模型训练集 $RMSE$ 平均 11.3 cm, MAE 为 3.0 ~ 16 cm, 有 30% 的站点 $MAE \leq 5$ cm, 有 70% 的站点 $MAE \leq 10$ cm。测试集结果与训练集评价结果差异不大。

由模型 1 组评价结果可见, 仅有部分站点的积涝模型有一定评估能力, 总体误差偏大, 不利于应急决策。由 2.2 节分析, 所有积涝站点的当前时次积水变化与历史积水深度有较高关联度, 因此将前 1 h 积水深度 (W_1) 选为特征因子; 降水因子中, 大部分站点和 1 h 累计降水量和上一时次 1 h 累计降水量关联度高于 3 ~ 6 h 累计降水量, 因此也作为重要的评估因子; 部分站点积水时间明显滞后于暴雨时间, 积水深度与 3 h 累计降水量的关联度高于 1 h 累计降水量, 做为备选因子; 6 h 累计降水量关联度最差, 为了简化模型, 在不降低评估精度的情况下, 在模型 2 中舍弃该因子。通过对比试验, 利用交叉验证法不断调节超参数, 最后选取训练集、测试集和交叉验证集 R^2 最大的一组模型, 确定为该站最后的积涝评估模型。由表 2, 1、2、3、6、7、9、10 等 7 站的内涝模型训练样本 R^2 都达到 0.9 以上, 平均 MAE 为 3.9 cm; 并且在测试样本中也能达到基本相当的水平, 说明模型有极好的泛化能力。核函数大部分站点使用 linear 核, 关联因子仅用 2 ~ 3 个, 就能达到较好的评估效果。从内涝程度来看, 上面 7 站内涝灾情相对严重, 特别是 119 站, 积水深度 ≥ 25 cm 的达 96 h, 占该站样本量的 47%, ≥ 50 cm 的达 36 h, 占样本量的 18%, 总样本量也最多为 205 个, 有利于提高模型的训练精度。4 站和 5 站模型 R^2 最差, 特别是 4 站, 训练集和测试集的 R^2 都不足 0.55。从实际降水和积水情况分析其原因, 125 站对应的气象站 1 h 最大降水量为 42.2 mm, 6 h 累计最大雨量也仅有 73 mm, 造成的最大积水深度仅有 19 cm, 样本量也仅有 78 个, 是 R^2 低的主要原因。

综上分析, 基于降水因子的内涝模型在部分站点有一定的评估能力, 但误差明显高于历史积水 + 降水的内涝评估模型。模型 1 组较模型 2 组平均 $RMSE$ 高 1.2 ~ 1.3 倍, 平均 MAE 高 1.0 ~ 1.2 倍。模型 2 组加入了历史积水因子后, 内涝评估精度和泛化能力大幅提高, 能够为防灾减灾提供较好的支撑。

表 2 支持向量机内涝评估模型评价

积涝 站点	模型	特征因子	核函数	训练集			测试集		
				RMSE	MAE	R^2	RMSE	MAE	R^2
1	1	$R1, R3, R6, R_{-1}$	Linear	10.716	7.144	0.731	5.928	5.168	0.748
	2	$W_{-1}, R_{-1}, R1$	Linear	5.244	4.104	0.924	5.320	3.952	0.910
2	1	$R1, R3, R6, R_{-1}$	Rbf	20.882	13.038	0.508	25.228	16.430	0.201
	2	$W_{-1}, R1$	Linear	6.996	4.770	0.919	9.116	6.042	0.910
3	1	$R1, R3, R6, R_{-1}$	Linear	8.636	6.936	0.770	8.840	6.664	0.730
	2	$W_{-1}, R_{-1}, R1$	Rbf	4.556	4.012	0.936	4.964	4.080	0.910
4	1	$R1, R3, R6, R_{-1}$	Rbf	3.800	3.021	0.440	4.978	4.009	0.155
	2	$W_{-1}, W_{-2}, R1, R3, R_{-1}$	Rbf	3.762	2.926	0.544	2.812	2.052	0.525
5	1	$R1, R3, R6, R_{-1}$	Rbf	4.420	3.706	0.699	5.202	4.624	0.523
	2	$W_{-1}, R1, R_{-1}$	Linear	3.672	2.924	0.798	4.216	3.060	0.646
6	1	$R1, R3, R6, R_{-1}$	Rbf	7.480	5.160	0.537	7.840	5.840	0.329
	2	$W_{-1}, R1, R_{-1}$	Linear	2.920	2.160	0.937	2.240	1.840	0.925
7	1	$R1, R3, R6, R_{-1}$	Linear	17.380	12.403	0.541	14.22	11.455	0.555
	2	$W_{-1}, R1, R3, R_{-1}$	Linear	7.742	5.925	0.908	7.584	6.004	0.908
8	1	$R1, R3, R6, R_{-1}$	Rbf	23.387	16.016	0.404	23.387	18.746	0.358
	2	$W_{-1}, R1, R3$	Rbf	8.827	7.280	0.920	10.829	7.644	0.829
9	1	$R1, R3, R6, R_{-1}$	Rbf	8.976	6.579	0.556	7.599	5.865	0.547
	2	$W_{-1}, R1, R_{-1}$	Linear	3.315	2.754	0.933	3.009	2.397	0.948
10	1	$R1, R3, R6, R_{-1}$	Rbf	7.511	4.144	0.339	8.991	4.662	0.213
	2	$W_{-1}, R1,$	Rbf	2.035	1.702	0.959	1.924	1.406	0.944

4 2021 年“7·20”特大暴雨实例应用

4.1 降水实况

2021 年 7 月 20 日 08:00—21 日 08:00(北京时,下同),开封市主城区出现特大暴雨,日累计降水量最大达 345.2 mm,其中开封国家气象站达 281.4 mm,是常年年平均降水量的 45.7%。由图 2 可见,强降水主要集中在 20 日 20:00—23:00 和 21 日 07:00,其中平均降水量超过 20 mm 的有 2 个时次,22:00 主城区平均降雨量达 79.7 mm,开封站最大降雨量 103.9 mm,为开封建站以来第 2 极端雨量;23:00 平均降雨量 36.1 mm,最大降雨量 46.2 mm。极端强降水给城市造成严重的内涝灾害。

4.2 评估结果分析

基于 2021 年 7 月 21 日 20:00—21 日 08:00 气象站降雨资料和内涝站积水深度监测数据,并筛选出 7 个资料较完整内涝站点的 91 个积水样本,对支持向量机回归评估模型 2 组进行检验。结果如表 3,有 5 个站点 R^2 达到 0.9 以上,平均 0.88; $RSME$ 在 1.89 ~ 6.34 cm,平均 4.33 cm, MAE 都在 3.7 cm 以内,平均 2.94 cm,模型评估结果表现优秀。从积水评估和实况折线图来看(图 3),能够较好地评估最大积水深度,涨水期和退水期;涨水期趋势与 3 h 降水量演变趋势更为一致。由于此次降水强度大,积水深度深,退水极为缓慢,说明降水强度已远远超过城市现有排涝能力。




图 2 2021 年 7 月 20 日 19:00—21 日 08:00 开封主城区气象站逐小时降水演变

表 3 2021 年“7·20”特大暴雨过程积涝评估结果评价

评价指标	9	6	5	1	7	8	10	平均
RMSE	4.22	3.91	5.32	4.46	6.34	4.22	1.89	4.33
MAE	3.33	3.50	3.64	3.14	2.72	3.33	0.96	2.94
R^2	0.95	0.87	0.57	0.96	0.91	0.95	0.97	0.88

5 结论与讨论

暴雨导致的城市内涝灾害,已成为当前我国大部分城市夏季的主要气象灾害之一。如何快速识别和评估内涝灾害显得尤为重要。本文在分析近年暴雨和内涝特征的基础上,应用灰色关联度方法,客观评价各因子对积涝的影响;应用支持向量机方法,构建了城市内涝评估模型;并以 2021 年“7·20”特大暴雨过程为例,对模型的适用性进行了评价。结论如下:

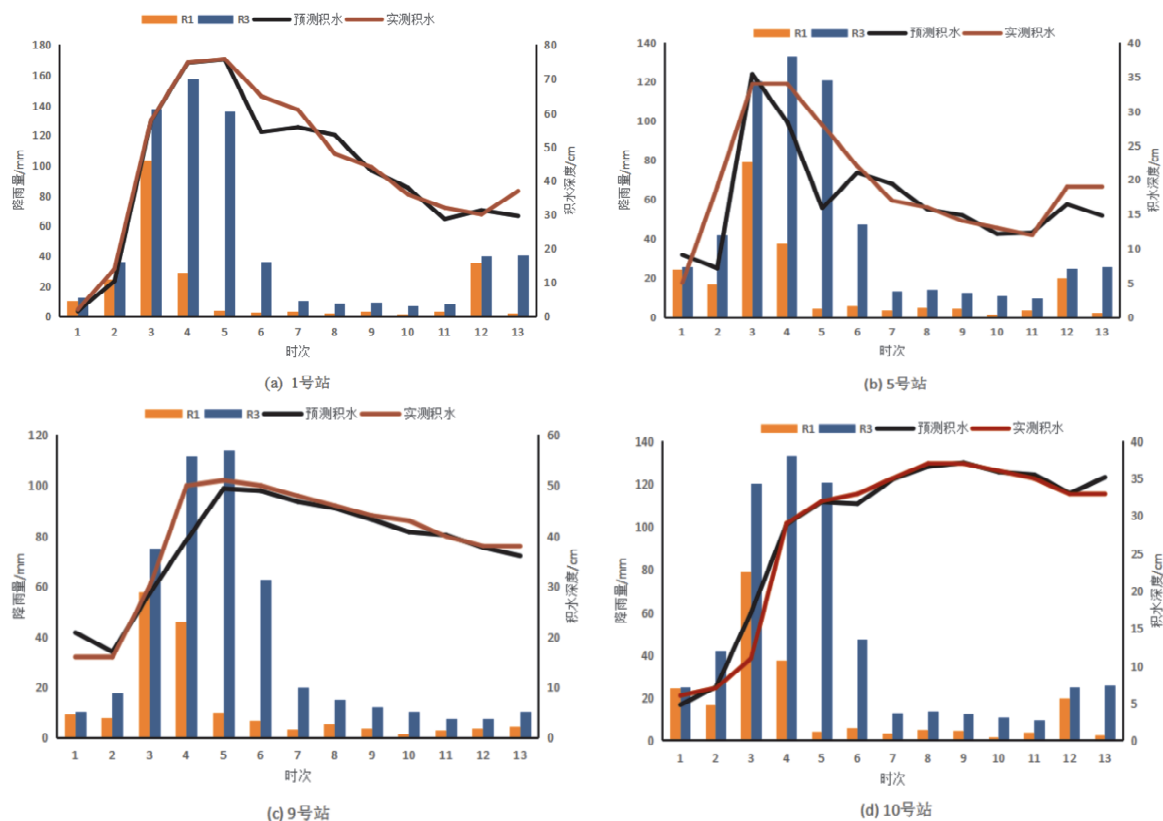


图3 2021年“7·20”特大暴雨过程积水站点实测与评估对比及1 h和3 h累计降水量演变

(1)较强的内涝过程主要由短时暴雨所致,其中3 h最大累计降水量平均占总降水量的83.1%,是内涝灾害形成的主要原因。同时积水自身也具有随时间变化的规律,当前时次积水深度与前1~2 h的历史积水深度关联度达到0.8以上,高于降水因子。积水与暴雨发生的时间相比,具有滞后1~3 h的特点。

(2)构建2组积水评估模型(模型1组基于降水因子,模型2组基于积水深度+降水因子),并进行对比评价,表明模型1组对内涝风险有一定评估能力,但总体误差明显高于模型2组。模型2组有80%的站点模型 R^2 超过0.9,训练集和测试集的平均 $MAE \leq 3.9$ cm,模型拟合结果评价优秀,并具有良好的泛化能力。

(3)2021年“7·20”极端暴雨过程中,模型2组 $RSME$ 平均4.33 cm, MAE 平均2.94 cm,较好地评估了极端暴雨内涝灾害的涨水期、退水期和最大积水深度,能够为城市防汛和应急决策提供较好的支撑。

城市内涝积水深度评估是一个复杂、影响因素较多的问题,受到下垫面、排水管网、地形等众多因素的影响。通过以上研究表明,支持向量算法能够快速学习降水和积水的拟合关系,显著缩短灾害风险评估时间。但机器学习方法高度依赖样本数据的准确性和完整性量,同时其得到的规律不会超出样本。随着城镇化快速发展,各城市地理信息、汇流、排水等环境情况也随之变化。因此需要持续积累样本,不断优化模型,才能真

正为防灾减灾提供科学支撑。

参考文献:

- [1] 游娜,陈刚毅. 城乡暴雨灾害的非规则结构化预测技术探讨[J]. 气象与减灾研究, 2015, 38(1): 59-65.
- [2] 薛春芳,王建鹏,薛荣,等. 基于GIS的西安城市强降水内涝预报预警系统[J]. 陕西气象, 2008(3): 6-9.
- [3] DU S Q, CHENG X T, HUANG Q X, et al. Brief communication: Rethinking the 1998 China floods to prepare for a nonstationary future[J]. Natural Hazards and Earth System Sciences, 2019, 19(3): 715-719.
- [4] 姜灵峰. 近76年我国洪涝灾损变化特征分析[J]. 气象科技进展, 2018, 8(5): 11-16.
- [5] 史军,穆海振,杨涵涵,等. 上海中心城区暴雨内涝阈值研究[J]. 暴雨灾害, 2016, 35(4): 344-350.
- [6] 魏军,俞海洋,胡会芳,等. 石家庄市城市内涝气象风险监测预警系统研制及应用[J]. 中国农村水利水电, 2019(2): 34-38, 43.
- [7] 朱呈浩,夏军强,陈倩,等. 基于SWMM模型的城市洪涝过程模拟及风险评估[J]. 灾害学, 2018, 33(2): 224-230.
- [8] 胡彩虹,杜纤,赵彦增,等. 平原地区SWMM模型空间尺度确定原则研究:以郑州市为例[J]. 人民珠江, 2019, 40(12): 18-24.
- [9] 朱颖蕾,于永强,俞芳琴,等. 基于MIKE21和MIKE Urban耦合的湖区平原城市内涝模拟应用研究[J]. 中国农村水利水电, 2018(10): 177-181, 185.
- [10] BAI G G, HOU J M, HAN H, et al. Intelligent monitoring method for road inundation based on deep learning[J]. Water Resources Protection, 2021, 37(5): 75-80.
- [11] LIU Y, LIU Y, ZHENG J, et al. Intelligent prediction method for waterlogging risk based on AI and numerical model[J]. Water, 2022, 14(15): 2282.

(下转第99页)