

排水管道泥沙淤积深度估算方法研究

吴慧英¹, 江凯兵¹, 李天兵², 邹新军¹, 钟英强³

(1. 湖南大学土木工程学院 建筑安全与节能教育部重点实验室, 湖南 长沙 410082; 2. 广州中工水务信息科技有限公司, 广东 广州 510280; 3. 中国地质大学 地理与信息工程学院, 湖北 武汉 430074)

摘要: 运用C#编程语言实现了SWMM模型参数的自动提取,通过创建BP-人工神经网络实现了节点水深值与模型参数值之间的非线性拟合,基于模型参数率定的思路提出了一种排水管道泥沙淤积深度的估算方法,并且以G市某雨水排水系统为例,采用4场降雨数据对模型进行了校核与验证。结果表明,通过两场降雨数据的验证,对于管径为1.2~1.8 m的管道,淤积深度预测值与实测值之间的绝对误差均在4 cm以内;模拟结果和实测数据的水深峰现时间偏差均低于实测数据历时的5%,峰值的数值偏差均在3%以内;场次3和场次4两场降雨4个监测点的水深预测值与实测值的平均相对误差分别为3.35%、2.98%、2.75%、2.51%、7.39%、6.77%、5.53%、8.15%,说明该方法能够对排水管道淤积情况进行有效预测。

关键词: 泥沙淤积深度; 排水管道; 雨洪管理模型; 参数率定; C#编程语言; 人工神经网络

中图分类号: TU992 **文献标识码:** A **文章编号:** 1000-4602(2020)01-0117-06

Estimating Method of Sediment Deposition Depth in Drainage Pipeline

WU Hui-ying¹, JIANG Kai-bing¹, LI Tian-bing², ZOU Xin-jun¹, ZHONG Ying-qiang³

(1. Key Laboratory of Building Safety and Energy Efficiency <Ministry of Education>, College of Civil Engineering, Hunan University, Changsha 410082, China; 2. Guangzhou Zhonggong Water Information Technology Co. Ltd., Guangzhou 510280, China; 3. School of Geography and Information Engineering, China University of Geosciences, Wuhan 430074, China)

Abstract: The automatic extraction of SWMM model parameters was realized by using C# programming language, and the nonlinear fitting between nodal water depth value and model parameter was realized by building a BP-artificial neural network (ANN). Based on the idea of parameter calibration of storm water management model (SWMM), a method for estimating the sediment deposition depth of drainage pipelines was proposed. The model was checked and validated with data of four rainfall events a rainwater drainage system of G city. By model validation with data of two rainfall events, the absolute error between the predicted and measured values of sedimentation depth in pipelines with diameters between 1.2 m and 1.8 m was within 4 cm. The deviation of water depth peak appearance time between the simulated results and the measured data was below 5% of the measured duration, and the deviation of the water depth peak value was within 3%. The average relative errors between the simulated

and measured water depth of rainfall 3 and 4 at the four monitoring points were 3.35% and 2.98%, 2.75% and 2.51%, 7.39% and 6.77% and 5.53% and 8.15%, respectively, indicating that this method could effectively predict the sedimentation of drainage pipelines.

Key words: sediment deposition depth; drainage pipeline; SWMM; parameter calibration; C# programming language; artificial neural network

近年来,随着我国城镇化的快速发展与市政基础设施的不断建设,城市不透水表面增加,雨水汇流速度加大,导致城市排洪防涝日趋紧张。同时,市政排水管道因多种原因引起管内泥沙淤积,导致排水不畅,进一步加剧了城市内涝问题^[1]。保持城市下水道畅通也是排水管道运营管理的重要工作内容之一,但快速有效地找出泥沙淤积严重的排水管道是管理维护的难点。目前,国内的城市排水管道维修保养技术主要是电视声呐检测和非开挖修复^[1],管道淤积问题的发现主要依赖定期巡检和对应急事件的处理,缺乏计算机手段支撑,巡检工作效率较低。

文碧岚等人^[2]的研究表明,用上下游检查井水深测试,并借助排水管网水力模型,可判断管道淤积状况。因此,针对排水管道普遍存在的淤积问题,笔者以G市某雨水排水系统为研究对象,采用C#编程语言进行数据提取、BP-人工神经网络进行非线性拟合、SWMM模型进行模拟,分析排水管道泥沙淤积状况,并在此基础上研究基于节点水深监测与模型模拟的排水管道泥沙淤积深度估算方法。其研究成果可为排水管道淤积问题提供一种利用计算机进行模拟分析的手段,旨在为解决城市内涝问题提供一种新的思路与方法。

1 模型研究

1.1 模型的选用及特点

选取SWMM模型作为水动力演算工具,能够为BP-人工神经网络提供输入输出数据;采用C#编程进行SWMM模型输入文件(.inp)、模拟结果文件(.rpt和.out)数据的提取与处理,并提供BP-人工神经网络模型的训练数据。SWMM是动态的降雨-径流模拟模型,可对城市单场暴雨或长时间降雨产生的径流进行水量和水质的动态模拟^[3]。

BP-人工神经网络算法又称为误差逆传播算法,具有误差既能正向传播、也可反向传播的特点。反向传播是根据输出节点的实际输出与理想输出的误差,从输出层→隐含层→输入层逐次修改连接权值,从而减少误差^[4]。C#拥有C/C++的强大功能以

及Visual Basic简易使用的特性^[5]。

1.2 技术路线

本研究基于SWMM模型参数率定的思路进行,需要率定的参数见表1^[6]。

表1 SWMM模型主要参数

Tab.1 Main parameters of SWMM

编号	参数名称	取值范围
1	N-Imperv	0.005 ~ 0.05
2	N-perv	0.05 ~ 0.50
3	S-Imperv	0.2 ~ 10
4	S-perv	2.0 ~ 10.0
5	Pct-Zero	5 ~ 85
6	Max. Infil. Rate	26 ~ 80
7	Min. Infil. Rate	0 ~ 10.0
8	Decay	2.0 ~ 7.0
9	Manning-N	0.011 ~ 0.024
10	Sediment coefficient	0 ~ 0.2

表1中前9个参数为常用率定参数,本研究的创新之处是首次提出了管道淤积系数(Sc),其计算过程见式(1)。取值范围由G市研究区域排水设施普查数据确定为0~0.2。针对不同区域,淤积系数的取值范围可根据当地历史资料或调查数据进行合理调整,值域为[0,1]。

$$Sc = \frac{Geom1}{Geom2} \quad (1)$$

式中:Sc为管道淤积系数;Geom1为管道中沉积物的深度;Geom2为圆形排水管道的直径。

参数率定技术路线如图1所示,率定分两步进行:第一步,采用排水系统总出水口在线监测水深数据作为验证数据,10个待率定参数统一进行率定,得到最优参数组合;第二步,采用同一道路管线上不同位置多个节点的在线监测水深数据作为验证数据,保持表1中前9个已在第一步完成率定的参数不变,以管道泥沙淤积系数作为单一变量,对水深监测点所在道路的每一管段进行率定,得到各管道最优泥沙淤积系数值,并用各对应管段的实测泥沙淤积深度进行验证。

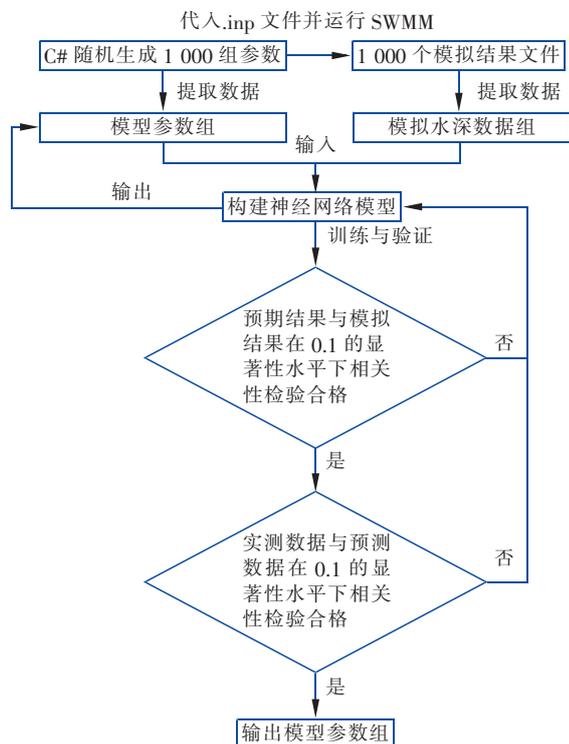


图 1 参数率定技术路线

Fig. 1 Technical route of parameter calibration

2 模型验证研究

将上述模型研究方法在 G 市某区域雨水排水系统管网中进行应用验证。该区域雨水排水系统管网如图 2 所示,研究区域总面积为 34.18 hm²,建筑物以住宅小区和商业大楼为主,地面主要为沥青地面,不透水面积率为 51%。图中有 125 个节点和 125 条管段,分别在图中的 J40、J44、J69、J74 节点处安装窨井水位计用于采集水深数据,节点 J44 拟设为排水系统的总出水口。

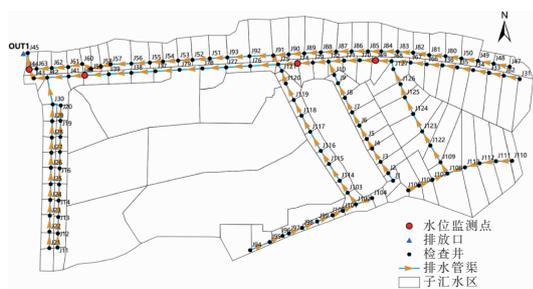


图 2 管网拓扑结构

Fig. 2 Topology of pipe network

管网数据来源于排水设施普查;地形数据和下垫面影像数据来源于数字高程模型、数字正射影像图以及现场勘查;校核与验证数据来源于在线雨量

计和窨井水位计实时采集的 4 场降雨数据和水位数据,采样时间间隔为 5 min,表 2 为所选降雨详细统计信息。

表 2 降雨统计信息

Tab. 2 Statistical information of rainfall

场次编号	降雨时间	降雨历时/min	降雨量/mm	备注
1	2018 年 8 月 17 日 17:25—19:15	110	22.5	大雨,用于校核
2	2018 年 8 月 21 日 21:10—21:50	40	4.5	小雨,用于校核
3	2018 年 8 月 28 日 01:15—03:15	120	25	大雨,用于验证
4	2018 年 9 月 1 日 09:05—10:05	60	15	中雨,用于验证

2.1 数据提取

通过 C#编程实现随机生成模型所需率定参数组,代入建好的 SWMM 模型.inp 文件中替换参数原始值,调用 SWMM 动态链接库(SWMM5.dll)运行模拟,得到模拟结果文件(.rpt 和.out)。本研究共产生 1 000 个样本用于模型的训练与验证^[7]。

BP-人工神经网络训练数据提取过程分两步:第一步,提取.out 文件中的 J44 节点随模拟时间变化的一系列水深数据作为输入数据(场次 1 共 36 个数据、场次 2 共 24 个数据),提取.inp 文件中的 10 个待率定参数作为输出数据;第二步,提取.out 文件中 J40、J44、J69、J74 节点随模拟时间变化的一系列水深数据作为输入数据(场次 1 共 144 个数据、场次 2 共 96 个数据),提取.inp 文件中与 4 个水深监测点在同一管线下 28 根管段的泥沙淤积系数作为输出数据。

2.2 人工神经网络的训练与预测

本研究的 BP-人工神经网络基于 MATLAB 神经网络工具箱构建,将输入、输出文件导入 MATLAB 工作区后,在命令行输入 nntool 打开神经网络工具箱,导入 Input Data 和 Target Data,新建不同隐含层节点数的 Feed-forward backprop 网络,并设置神经网络参数。

参数率定分两步进行,因采用两场降雨数据进行参数率定的校核,首先构建两个结构相似的神经网络模型 ANN1 和 ANN2 用于第一步参数率定。通过对两种降雨情景下不同隐含层节点的神经网络进行多次测试,确定隐含层节点数均为 16。同时,分

别随机生成 150 个样本,采用 SPSS 对 ANN1 和 ANN2 的拟合性能进行相关性分析^[8],预测值与期望值之间的相关系数见表 3。两个结果同时表明,除参数 N-perv、Decay 以外,其余 8 个参数的预测值与期望值之间呈极显著正相关($P < 0.01$),相关文献研究表明 N-perv、Decay 两个参数敏感性较小^[6]。因此,ANN1 和 ANN2 具备较好的预测性能,可用于本研究中的参数率定。分别保存两种情景下的神经网络模型并调用 sim 函数预测表 1 中的 10 个参数,预测结果见表 3。

表 3 10 个参数的预测结果

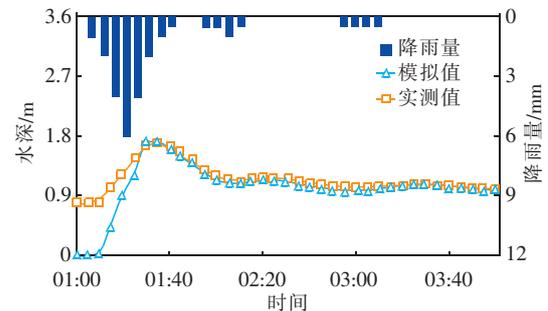
Tab. 3 Prediction results of 10 parameters

项 目	场次 1 的相关系数	场次 1 的预测值	场次 2 的相关系数	场次 2 的预测值
N-Imperv	0.846***	0.01	0.804***	0.01
N-perv	0.023	0.11	0.021	0.15
S-Imperv	0.924***	1.18	0.902***	1.14
S-perv	0.253***	8.96	0.262***	8.86
Pct-Zero	0.962***	29.8	0.935***	27.8
Max. Infil. Rate	0.358***	31.4	0.334***	32.0
Min. Infil. Rate	0.364***	8.6	0.357***	7.9
Decay	0.098	5.65	0.088	5.66
Manning-N	0.796***	0.013 5	0.776***	0.013 5
Sc	0.996***	0.1	0.990***	0.99

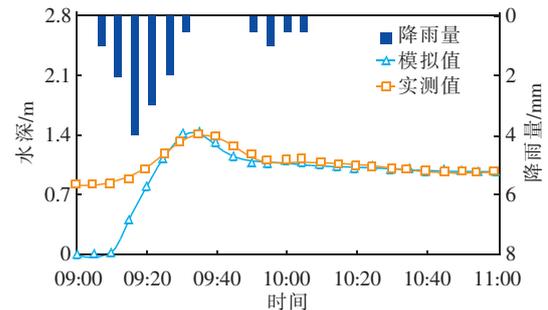
注: *、**、*** 分别表示 0.1、0.05 以及 0.01 的显著性水平。

表 3 中场次 1 和场次 2 的预测值较为接近,这里取其平均值代入 SWMM 模型,并分别在场次 3 和场次 4 下对参数率定结果进行验证分析。场次 3 和场次 4 的模型模拟流量连续性误差分别为 0.35% 和 0.53%,均低于 1%。提取模拟结果文件(.out)中 J44 节点的水深数据,并与该点实测水深进行对比分析,结果如图 3 所示。可以看出,模拟结果和实测数据的水深峰现时间偏差均为 5 min,均低于实测数据历时的 5%;模拟水深峰值和实测水深峰值的数值偏差均在 3% 以内。场次 3 和场次 4 中除降雨开始的 20 min 内水深数据相差较大以外,其他时刻的水深模拟值与实测值的平均相对误差分别为 2.42%、3.09%,相关系数分别为 0.991、0.950,具有较好的一致性。分析原因,降雨开始 20 min 内数据误差较大是因为实际排水管网中降雨前存有积水,而模型模拟是从降雨开始后计时,且排水管道在计时开始后才有雨水汇流进入,由此造成较大误差,此误差不影响模型对降雨过程的还原。因此,这里

较好地 对 SWMM 参数进行了初步率定。



a. 场次 3(2018 年 8 月 28 日大雨)



b. 场次 4(2018 年 9 月 1 日中雨)

图 3 J44 节点水深模拟值与实测值

Fig. 3 Simulated and measured water depth of node J44

为进行管道泥沙淤积深度估算,构建 ANN3 和 ANN4 用于第二步参数率定。通过对场次 1 和场次 2 两种降雨情景下不同隐含层节点的神经网络进行多次测试,确定隐含层节点数均为 17。同时,分别随机生成 150 个样本,采用 SPSS 对 ANN3 和 ANN4 的拟合性能进行相关性分析,预测值与期望值之间的相关系数见表 4。可知,G1、G2、G3、G8、G25、G27、G28、G29、G35、G36 等 10 根管段的预测值与期望值不具有显著相关性,其余 18 根管段的预测值与期望值具有不同显著性水平的相关性。分析管道拓扑结构可知,G1、G2、G3、G25、G27、G28、G29 这 7 根管段位于所在道路排水系统的起点,且其下游有较大的支管汇入,监测点的水深变化受这几段管道水深的影响较少,所以敏感性不高。G8、G35、G36 这 3 根管段位于两个水深监测点 J40、J74 之间,且距离两个监测点的距离都较远,由于未进行管网概化,监测点之间管段数量较多,且本研究中整个管线的淤积系数较小,造成监测点水深对中间管段淤积深度敏感性不高。如果经费及现场条件允许,增加管道监测点,可提高各管段预测值与期望值之间的显著性。虽然 ANN3 和 ANN4 对部分管道淤积深度的预测效果不佳,但并不影响其他管段对此方法的验证。

分别保存两种情景下的神经网络模型,并调用 sim 函数预测 28 个管道的泥沙淤积系数。

表 4 管道泥沙淤积参数

Tab.4 Parameters of sediment deposition in pipeline

项目	管径 /m	场次 1 的相关系数	预测淤积深度/cm	场次 2 的相关系数	预测淤积深度/cm	实测淤积深度/cm
G1	0.5	0.032	1.90	0.047	3.10	<5
G2	0.5	-0.009	1.70	0.011	0.50	<5
G3	0.5	-0.084	3.30	-0.069	3.50	8
G4	1.2	0.788***	8.61	0.781***	8.47	9
G5	1.2	0.982***	26.81	0.947***	25.65	23
G6	1.2	0.852***	1.62	0.863***	2.01	<5
G7	1.2	0.137**	1.31	0.152**	1.27	<5
G8	1.2	0.004	3.56	0.007	5.76	<5
G9	1.2	0.548***	1.30	0.524***	1.51	<5
G10	1.2	0.973***	6.86	0.944***	6.53	6
G11	1.8	0.882***	22.13	0.854***	22.53	20
G12	1.8	0.547***	1.99	0.602***	2.24	<5
G13	1.8	0.908***	32.72	0.904***	34.22	33
G25	0.4	-0.061	3.87	-0.048	6.60	8
G26	0.4	0.113*	4.90	0.116*	4.67	<5
G27	0.4	0.077	4.00	0.059	5.80	6
G28	0.5	-0.061	2.41	-0.085	5.70	7
G29	0.5	-0.044	8.25	-0.061	5.42	9
G30	1.8	0.548***	1.85	0.542***	2.10	<5
G31	1.8	0.212***	1.85	0.211***	1.71	<5
G32	1.8	0.869***	21.40	0.869***	20.70	22
G33	1.8	0.559***	32.67	0.553***	31.60	29
G34	1.8	0.445***	2.83	0.451***	2.95	<5
G35	1.8	-0.056	3.24	-0.065	7.52	14
G36	1.8	-0.011	22.86	-0.015	20.46	15
G37	1.8	0.392***	1.98	0.380***	2.07	<5
G38	1.8	0.863***	1.80	0.867***	2.01	<5
G39	1.8	0.834***	22.32	0.826***	21.84	24

注: *、**、*** 分别表示 0.1、0.05 以及 0.01 的显著性水平。

本研究还对表 4 所列管道的实际淤积深度值进行了人工现场测量,并与预测值进行了比较。现场测量采用工程 L 杆测量和 QV 视频检测^[9],对于表 4 所列管道的管径而言,<5 cm 的淤积深度可忽略不计,且因其淤积深度值太小,测量误差较大,因此未列出具体测量值。从表 4 还可以看出,在显著性相关的 18 根管段中,预测淤积深度与实测淤积深度的绝对误差均在 4 cm 以内(管道管径为 1.2 ~ 1.8 m),具备较好的预测效果。

表 4 中场次 1 和场次 2 具备显著性相关管段的

预测值较为接近,这里取平均值,其余管段取实测值代入 SWMM 模型,并分别在场次 3 和场次 4 下对率定结果进行验证分析。场次 3 和场次 4 的模型模拟流量连续性误差分别为 0.34% 和 0.52%,均低于 1%。提取 4 个监测节点的模拟水深数据,并与相应节点的实测水深进行比较,结果如图 4 所示。

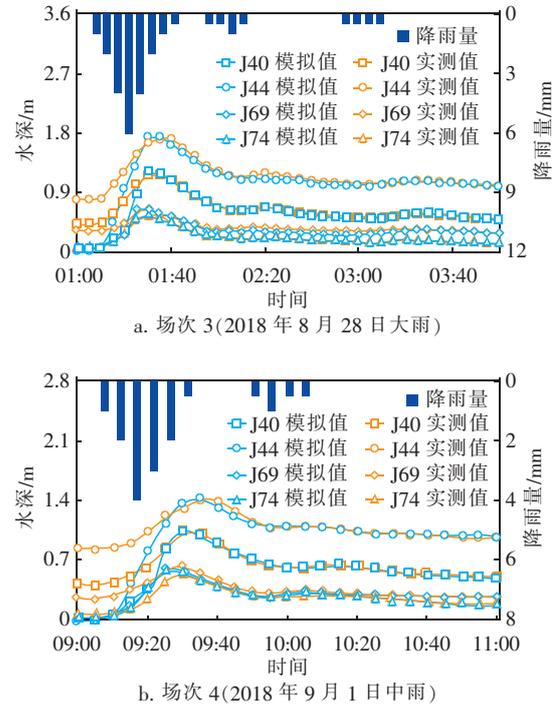


图 4 节点水深模拟值与实测值对比

Fig.4 Comparison of simulated and measured water depth of nodes

由图 4 可以看出,模拟结果和实测数据的水深峰现时间偏差均为 5 min,全都低于实测数据历时的 5%;模拟水深峰值和实测水深峰值的数值偏差均在 3% 以内。除开始降雨的两个时刻水深数据外(其原因与图 3 相同),其他时刻的水深模拟值与实测值有较好的一致性,场次 3 和场次 4 中 J40 节点水深平均相对误差分别为 3.35%、2.98%,相关系数分别为 0.992、0.996;J44 节点水深平均相对误差分别为 2.75%、2.51%,相关系数分别为 0.983、0.970;J69 节点水深平均相对误差分别为 7.39%、6.77%,相关系数分别为 0.989、0.985;J74 节点水深平均相对误差分别为 5.53%、8.15%,相关系数分别为 0.994、0.957。

综上所述,采用本方法对排水管道泥沙淤积深度及不同降雨历时排水管道水深进行估算是可行

的,与实测值有较好的吻合度。

3 结论

基于 SWMM 模型参数率定的思路,利用 C#实现了模型数据的提取,基于 MATLAB 创建了 BP - 神经网络对输入输出数据进行非线性拟合,并实现了预测,从而达到了参数自动率定的目的。提出了一种排水管道泥沙淤积深度的估算方法,并在 G 市某雨水排水系统中进行了模型验证。

① 以 G 市某雨水排水系统为研究对象,以 4 场降雨数据和节点水位数据为校核与验证数据,采用 BP - 神经网络对 SWMM 模型参数完成了自动率定。

② 针对研究区域部分管道完成了泥沙淤积深度估算及不同降雨历时排水管道的水深预测,并通过预测淤积深度与实测淤积深度及多节点的模拟水深与实测水深的双对比验证,对管径为 1.2 ~ 1.8 m 的管道,预测淤积深度与实测淤积深度的绝对误差均在 4 cm 以内。模拟结果和实测数据的水深峰现时间偏差均低于实测数据历时的 5%,峰值的数值偏差均在 3% 以内,表明预测值与实测值具有较好的吻合度。说明此方法在一定条件下可用于排水管道泥沙淤积深度估算。

③ 通过对排水管道淤积情况的有效预测,可为排水管道的管理维护提供计算机模拟分析理论依据,同时能够为排水管道养护及缓解城市内涝提供新的管理技术与思路。

参考文献:

- [1] CJJ 68—2016,城镇排水管道与泵站运行、维护及安全
技术规程[S]. 北京:中国建筑工业出版社,2016.
CJJ 68 - 2016, Technical Specification for Operation,
Maintenance and Security of Sewers & Channels and
Pumping Stations in City and Town[S]. Beijing: China
Architecture & Building Press,2016(in Chinese).
- [2] 文碧岚,李树平,沈继龙,等. 排水管道淤积状况模拟
分析[J]. 给水排水,2015,41(7):151 - 157.
Wen Bilan, Li Shuping, Shen Jilong, *et al.* Modelling of
sewer sedimentation accumulating [J]. Water &
Wastewater Engineering, 2015, 41 (7): 151 - 157 (in
Chinese).
- [3] Niazi M, Nietch C, Jackson N, *et al.* Storm water
management model: Performance review and gap analysis
[J]. J Sustainable Water Built Environ, 2017, 3 (2):

04017002.

- [4] Olawoyin R. Application of backpropagation artificial
neural network prediction model for the PAH
bioremediation of polluted soil [J]. Chemosphere, 2016,
161:145 - 150.
- [5] Solis D M. C#图解教程[M]. 4 版. 姚琪琳, 苏林, 朱
晔, 等译. 北京:人民邮电出版社,2013.
Solis D M. Illustrated C# 2012[M]. 4th ed. Translated
by Yao Qilin, Su Lin, Zhu Ye, *et al.* Beijing: Posts &
Telecom Press Co. Ltd., 2013(in Chinese).
- [6] 熊剑智. 城市雨洪模型参数敏感性分析与率定[D].
济南:山东大学,2016.
Xiong Jianzhi. Urban Stormwater Model Parameter
Sensitivity Analysis and Calibration[D]. Jinan: Shandong
University, 2016(in Chinese).
- [7] Li C Q, Wang W, Xiong J Z, *et al.* Sensitivity analysis for
urban drainage modeling using mutual information [J].
Entropy, 2014, 16(11):5738 - 5752.
- [8] Morgan G A, Leech N L, Gloeckner G W, *et al.* IBM
SPSS for Introductory Statistics: Use and Interpretation
[M]. 5th ed. London:Routledge, 2012.
- [9] 李若晗. 城市污水管道检测、评价与影响因素研究
[D]. 北京:清华大学,2016.
Li Ruohan. A Study of Urban Sewer Inspection,
Assessment and Related Factors [D]. Beijing: Tsinghua
University, 2016(in Chinese).



作者简介:吴慧英(1967 -),女,湖南岳阳人,博士,
副教授,主要研究方向为水质净化与水污染
控制。

E - mail: wuhuiying03@126.com

收稿日期:2019 - 06 - 22