

DOI:10.11918/201908056

GA 优化 ELM 神经网络的排水管道缺陷诊断

郑茂辉¹, 刘少非^{1,2}

(1. 同济大学 上海防灾救灾研究所, 上海 200092; 2. 同济大学 土木工程学院, 上海 200092)

摘要: 为及时发现排水管道安全隐患, 准确掌握管道状况, 结合极限学习机(extreme learning machine, ELM)神经网络和管道闭路电视(closed circuit television, CCTV)检测, 建立一个数据驱动的排水管道缺陷诊断模型. 采用遗传算法(genetic algorithm, GA)优化 ELM 神经网络的输入权值矩阵和隐含层偏置, 改善网络参数随机生成带来的 ELM 模型输出不稳定、分类精度偏低的问题. 以上海市洋山保税港区排水管道破裂、渗漏等主要结构性缺陷的诊断为例, 对 GA-ELM 模型进行仿真分析, 并与 ELM 模型诊断结果进行对比. 结果表明, GA-ELM 模型能够更好地识别管道缺陷, 获得更佳的分类型性能, 参数优化提高 ELM 模型的拟合能力和泛化能力, 可应用于城市排水管道状况评价, 为排水管网养护计划和修复计划的制订提供技术依据.

关键词: 排水管道; 缺陷诊断; 极限学习机; 遗传算法; 神经网络; CCTV 检测

中图分类号: TU992

文献标志码: A

文章编号: 0367-6234(2021)05-0059-06

Defect diagnosis of urban drainage pipelines based on GA optimized ELM neural network

ZHENG Maohui¹, LIU Shaofei^{1,2}

(1. Shanghai Institute of Disaster Prevention and Relief, Tongji University, Shanghai 200092, China;

2. College of Civil Engineering, Tongji University, Shanghai 200092, China)

Abstract: To detect the potential risks of drainage pipelines and accurately grasp the pipeline conditions, a data-driven defect diagnosis model was established by combining optimized extreme learning machine (ELM) neural network and closed circuit television (CCTV) inspection. Genetic algorithm (GA) was adopted to optimize the input weight matrix and the hidden layer offset of ELM neural network, which helps to solve the problems of unstable output and low classification accuracy of ELM neural network caused by random generation of network parameters. Taking the drainage pipeline dataset from Yangshan Free Trade Port Area in Shanghai as an example, the proposed GA-ELM model was conducted to identify and diagnose major structural defects, such as pipe rupture, disconnect, and leakage. The results of the GA-ELM model were compared with those of ELM model on the same dataset. It shows that the GA-ELM model achieved better classification performance by utilizing same neuron nodes in the hidden layer, and the optimization of parameters improved the fitting capability and generalization ability of the ELM model. Therefore, the proposed method is applicable to defect diagnosis and evaluation of urban drainage pipes and can provide a technical basis for the formulation of drainage network maintenance plan and repair plan.

Keywords: drainage pipeline; defect diagnosis; extreme learning machine (ELM); genetic algorithm (GA); neural network; CCTV inspection

近 20 年来, 中国排水管网系统发展迅速. 随着管网规模的不断扩大和服役年限的增长, 排水管道退化和缺陷问题也逐步凸显, 有些管道缺陷直接导致路面塌陷、水体污染等严重事故, 不仅影响城镇居民工作和生活, 还对生命健康构成威胁. 排水管道内部缺陷的识别、诊断是制定管网养护计划和修复计划的重要依据, 也是城市安全运行监管的重要内容之一.

排水管道缺陷包括管道破裂、腐蚀、渗漏、变形等结构性缺陷, 以及沉积、结垢、障碍物等功能性缺陷. 管道闭路电视(closed circuit television, CCTV)检测是目前国内外用于管道状况检查最为成熟、有效、安全的技术手段. 能直观反映和记录管道内部真实情况, 通过管道影像的判读, 识别内部缺陷类型、位置和等级, 并做进一步评估分析^[1]. 不过, CCTV检测要求对管道先进行一定清理, 降低管内水位, 前期工作量大; 另外, 主要依靠人工目测对管道内部状况和缺陷进行诊断评估, 效率较低. 国内外学者采用统计和机器学习方法研究建立了多种管道状况模型. 例如, Micevski 等^[2]基于马尔科夫链构建雨水管

收稿日期: 2019-08-06

基金项目: 国家重点研发计划项目(2016YFC0802400, 2017YFC0803300)

作者简介: 郑茂辉(1976—), 男, 副研究员

通信作者: 郑茂辉, zmh@tongji.edu.cn

道结构退化模型,并用贝叶斯方法进行校准;刘威等^[3]结合全概率公式及线性腐蚀模型给出管线面积腐蚀率的概率密度随服役时间变化的解析表达式; Mashford 等^[4]建立了基于支持向量机的管道状况预测模型,并应用于澳大利亚阿德莱德市排水管网状况评价; Rober 等^[5]利用 CCTV 检测数据和随机森林算法,对加拿大圭尔夫市下水管道的结构性状态进行预测. 此外, Tran 等^[6-7]利用神经网络模型预测排水管道的结构性状况和水力性状况. 不过,已有研究更多的是对管道整体状况的建模,从结构性或功能性方面预测管道风险等级,具体缺陷类型的分类诊断和评价方面还有待更深入的研究.

鉴于管道退化和缺陷影响因素复杂,数据驱动的神经网络模型无需深入理解管道病害机理,通过数据样本监督学习即可建立管道缺陷状况同相关特征变量的关联模式,无疑具有良好的适用性和应用前景^[8]. 极限学习机 (extreme learning machine, ELM) 是 Huang 等^[9]基于 Moore-Penrose 矩阵理论提出的一种单隐含层前馈神经网络算法,相对传统的神经网络,具有结构简单、学习效率高、泛化能力强等优点. 不过, ELM 随机生成输入层权值以及隐含层节点偏置等网络参数的特点,可能造成部分隐含层节点的失效^[10]; 其次, ELM 分类预测精度与隐含层节点数密切相关,但过多隐含层节点数会导致模型泛化能力的下降,影响管道缺陷分类诊断的能力.

为此,采用遗传算法 (genetic algorithm, GA)^[11]优化 ELM 网络参数,充分利用管道基础数据和 CCTV 检测资料,建立一个新型的城市排水管道缺陷诊断模型,并以上海市洋山港保税区排水管道结构性缺陷的分类诊断为例开展实证研究,验证模型方法的适用性和有效性.

1 GA-ELM 诊断模型

1.1 ELM 原理

设 n, L, m 分别为输入层、隐含层和输出层的节点数, 给定 N 组任意的排水管道数据样本 $(\mathbf{x}_i, \mathbf{t}_i) \in \mathbf{R}^n \times \mathbf{R}^m$, ELM 的输出可以表示为

$$f_L(\mathbf{x}) = \sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = \mathbf{o}_j, j = 1, \dots, N. \quad (1)$$

式中: $g(\mathbf{x})$ 为激励函数, $\mathbf{w}_i = [\mathbf{w}_{i1}, \mathbf{w}_{i2}, \dots, \mathbf{w}_{in}]^T$ 为隐含层第 i 个神经元与输入层的连接权值, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为隐含层第 i 个神经元与输出层的连接权值, b_i 为隐含层神经元的阈值. $\mathbf{w}_i \cdot \mathbf{x}_j$ 为 $\mathbf{w}_i$ 和 $\mathbf{x}_j$ 的内积.

若 $L = N$, 则对于任意给定的 β_i 和 $\mathbf{w}_i$, ELM 能零误差逼近学习样本^[12], 式(1)可以由矩阵形式表

达为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}. \quad (2)$$

其中

$$\mathbf{H} = \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix} = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & \cdots & g(\mathbf{w}_L \cdot \mathbf{x}_1 + b_L) \\ \vdots & & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & \cdots & g(\mathbf{w}_L \cdot \mathbf{x}_N + b_L) \end{bmatrix}_{N \times L}, \quad (3)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad (4)$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times m}. \quad (5)$$

N 较大时, 为减少计算量通常取 $L < N$, 此时, 对 ELM 的网络训练等价于如下优化问题:

$$\|\hat{\mathbf{H}}\boldsymbol{\beta} - \mathbf{T}\| = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\|. \quad (6)$$

当 $g(\mathbf{x})$ 无限可微时, 随机给定网络参数 $\mathbf{w}_i$ 和 b_i , ELM 模型训练过程可看作求解线性系统 $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$ 关于 $\hat{\boldsymbol{\beta}}$ 的最小二乘解, 即

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T}. \quad (7)$$

$\mathbf{H}^+$ 为隐含层输出矩阵 $\mathbf{H}$ 的 Moore-Penrose 广义逆.

1.2 GA 优化 ELM

与 BP 模型相比, ELM 学习速度快、泛化性能强、不易陷入局部极值, 但仍有一些问题, 如该算法中输入权值和隐含层偏置的随机选取导致隐含层神经元几乎不存在调节能力, 这就对网络参数的优化提出了较高的要求. 同时, ELM 可能存在网络结构复杂、稳定性差等问题, 选择合适的隐含层神经元个数和激活函数十分重要.

GA 是模拟自然界遗传机制和物种进化而形成的一种并行随机搜索优化方法, 将需要优化的参数编码形成串联群体, 然后按照适应度函数通过选择、交叉和变异对个体进行筛选, 最终选择适应度最优的个体^[11]. 采用 GA 优化 ELM 神经网络的输入权值 $\mathbf{w}_i$ 和隐含层偏置 b_i , 得到最优的网络参数建立 GA-ELM 神经网络, 提高模型输出的准确度和稳定性.

GA-ELM 算法集成了 GA 全局搜索最优能力和 ELM 的强学习能力. 在该算法中, 将 ELM 训练数据的输入权值和隐含层节点偏置映射为 GA 种群中每条染色体上的基因, GA 的染色体适应度对应于 ELM 的训练误差, 将求取最优输入权值、偏置问题转化为计算染色体适应度, 选择最优染色体问题.

图 1 给出 GA-ELM 算法流程,主要包括 ELM 网络确定、遗传算法优化和 ELM 网络的训练、预测等。




图 1 GA-ELM 算法流程

Fig. 1 Calculation flow of GA-ELM algorithm

算法相关思路及处理方法如下:

1) 种群初始化. 确定 ELM 神经网络的拓扑结构,即输入层、隐含层和输出层的神经元个数;设置最大进化代数 G ;随机生成 ELM 神经网络的输入权值和隐含层偏置,并对其进行二进制编码,产生初始种群;个体的长度由隐含层输入权值矩阵和偏置向量构成,即 $D = (n + 1)L$,其中 L 为隐含层节点数, n 为输入层神经元个数,即输入向量维度。

2) 个体适应度评价. 对于每一代种群中的任意一个个体,采用 ELM 算法计算输出权值矩阵,并得到样本的期望输出与实际输出的均方根误差,作为 GA 目标函数

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^n (y_i - y)^2}{n}}. \quad (8)$$

式中: i 为样本个体, n 为样本总数, y_i 为仿真输出值, y 为样本期望输出值. 目标函数数值越小,模型越精确。

3) 种群进化. 根据个体的适应度,采用轮盘赌法对每一代种群中的染色体进行选择,利用基于概率的交叉、变异操作对选中的个体进行优化,产生新的种群,直至满足约束条件,如达到最大迭代次数或相邻种群的平均目标值、最小目标值变化很小时终止进化,得到最终的种群。

4) ELM 网络训练和预测. 对迭代优化后的最终种群解码,得到优化后的输入权值和偏置,赋予 ELM,使用训练样本对 ELM 网络进行训练,采用最

小二乘法计算输出层权值 $\hat{\beta} = H^+ T$,最后将测试样本代入 ELM 模型进行预测输出。

1.3 模型构建与评价

排水管道退化机理复杂,影响因素较多,本文只针对管道结构性缺陷识别,利用 GA-ELM 算法建立分类诊断模型,通过样本数据训练学习确定影响因素与结构性缺陷之间的非线性关系. 图 2 给出模型的网络拓扑结构. 其中, x_j 代表模型的输入变量,即管道结构性退化影响因素; t_i 代表模型输出变量,即结构性缺陷类型,如破裂、渗漏、脱节、变形、错位、腐蚀等。




图 2 模型网络拓扑

Fig. 2 Structure of neural network

影响管道结构性退化的因素包括管道自身物理属性,如管材、管龄、管径、管长、埋深、坡度等;外部环境因素,如路面交通荷载、环境温度变化、临近施工、土壤类型、地下水位、树根侵入因素等. 借鉴已有退化指标分析成果^[8,13-14],结合工程应用中数据获取条件,选取管材、管龄、管径、埋深、管长、坡度、管道类型、土壤类型和所在道路等级共 9 项特征参数作为神经网络模型的输入变量. 其中,管道埋深取上下游节点埋深的平均值;管道所在道路等级分为主干道、次干道和其他道路 3 类,间接表征路面交通荷载. 结构性缺陷类型,即样本标签由 CCTV 检测结果给定。

为了检验 GA-ELM 模型分类诊断效果,采用混淆矩阵方法对分类器性能进行分析评价. 假定 n_{ij} 表示被分类为 j 类的 i 类样本数, K 为样本种类,则分类精度 A 以正确分类的样本数与总样本数 N 的比值表示,即

$$A = \frac{\sum_{i=1}^K n_{ii}}{N} \times 100\%. \quad (9)$$

定义 R_i 为第 i 类样本的查全率 (Recall), 即

$$R_i = \frac{n_{ii}}{\sum_{j=1}^K n_{ij}} \times 100\%. \quad (10)$$

定义 G_{mean} 为样本所有类别查全率的几何平均值:

$$G_{\text{mean}} = \left(\prod_{i=1}^K R_i \right)^{\frac{1}{K}} \times 100\%.$$

(11)

G_{mean} 的基本思想是使每一分类正确率尽可能大的同时,保持各类之间的平衡,是评价不平衡数据集上分类器性能的重要指标.

2 实验分析

2.1 实验数据

以上海市浦东新区洋山保税港区公共排水管道为对象,开展实证研究. 主要数据来源包含两部分: 一是测绘部门提供的管道 GIS 数据,包含管材、管龄、管径、埋深、管长、坡度、管道类型和所在道路等属性数据;二是由管道养护单位提供的实验区 2018 年 10 月份管道 CCTV 检测数据,检测管道里程约 45.5 km. CCTV 检测报告给出了具体管段的缺陷类型、等级,并计算了管段修复指数和养护指数. 为简化网络模型,提高模型分类预测性能,研究仅选取实验区管道“破裂”、“脱节”、“渗漏”3 类主要结构性缺陷类型和“正常”共 4 类样本数据. 基于管段唯一性标识建立管网 GIS 和 CCTV 检测数据的对应关系,提取有效样本数据共 1 251 条. 按 4 类样本的占比随机选取 1/4 样本作为测试样本集,3/4 样本作为训练样本集,样本数据组成如表 1 所示.

表 1 样本数据
Tab. 1 Sample data

缺陷分类	训练集	测试集	期望输出
正常	338	112	[1 0 0 0]
破裂	188	62	[0 1 0 0]
脱节	147	48	[0 0 1 0]
渗漏	267	89	[0 0 0 1]

对于管材、道路等级、土壤类型、缺陷类型等离散的分类特征数据,采用独热编码进行数字化. 另外,为避免各指标量纲和数量级不同造成的不平衡性,提高神经网络模型的收敛速度和学习预测能力,采用最大最小法对样本数据进行了归一化处理,使得处理后的数据分布范围在 $[0,1]$,公式如下:

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}}.$$

(12)

式中: X 为实测值, $X_{\min}$ 为样本数据的最小值, $X_{\max}$ 为样本数据的最大值.

2.2 参数设置

利用标准 ELM 构建管道缺陷分类诊断模型时,仅需要设定隐含层神经元节点数 L 和激励函数 $g(x)$ 的构造形式就可以求算输出权值矩阵. 实际工

程应用中隐含层神经元节点数 L 一般远小于样本数 N , L 过小网络预测误差较大, L 过大则会增加模型预测的时间空间成本,容易出现过拟合现象. 图 3 给出 sigmoid、sin 和 hardlim 3 种常见激励函数下隐含层神经元节点数 L 对分类器能力的影响. 其中, sigmoid 函数的分类器性能整体较好, L 增至 120 时 G_{mean} 相对较高,为 55.39%. 对于标准 ELM 模型,选定 sigmoid 激励函数,隐含层神经元节点数 L 设定为 120.




图 3 3 种激励函数下隐含层节点数对 ELM 分类性能的影响

Fig. 3 Effect of number of hidden nodes on ELM performance under three activation functions

为方便比较,选择同样的激励函数和隐含层节点数,对 GA-ELM 分类器性能进行仿真分析. 设定 GA 参数如下:种群大小为 40,最大遗传代数为 100,交叉概率 0.7,变异概率 0.01,代沟 0.95. 将样本输入 GA-ELM 模型进行训练,如图 4 误差进化曲线所示,当进化到 44 代时,误差最小,满足要求. 因此,将 44 代优化后的权值和偏置代入极限学习模型中对测试样本进行预测.




图 4 误差进化曲线

Fig. 4 Error evolution curve

2.3 分类结果分析

表 2 给出标准 ELM 和 GA 优化后模型分类性能的比较. 其中,ELM 在训练集上的分类精度 $A = 70.74\%$, $G_{\text{mean}} = 65.21\%$; 测试集训练精度 $A =$

65.59%, $G_{\text{mean}} = 55.39\%$. GA 优化 ELM 网络参数后,对于训练样本和测试样本的分类能力均有显著提升,达到 80% 以上,而且 GA-ELM 整体上具有更好的稳定性和泛化能力.

表 2 GA-ELM 和 ELM 模型分类性能比较 %				
Tab. 2 Performance comparison between GA-ELM and ELM				
模型	训练精度		测试精度	
	A	G_{mean}	A	G_{mean}
GA-ELM	87.46	85.07	82.96	80.50
标准 ELM	70.74	65.21	65.59	55.39

为进一步分析模型对不同管道缺陷类型的诊断、识别能力,表 3 以混淆矩阵形式给出 GA-ELM 和

表 3 GA-ELM 和 ELM 诊断结果										
Tab. 3 Diagnosis results of GA-ELM and ELM										
观测结果	GA-ELM 诊断结果					ELM 诊断结果				
	正常	破裂	脱节	渗漏	$R_i/\%$	正常	破裂	脱节	渗漏	$R_i/\%$
正常	106	0	2	4	94.64	100	0	0	12	89.29
破裂	0	48	7	7	77.42	0	37	10	15	59.68
脱节	0	7	36	5	75.00	0	17	25	6	52.08
渗漏	0	8	13	68	76.40	3	14	14	58	65.17

图 5 给出测试集上逐个样本 GA-ELM 诊断结果与观测值的比照. 结果也表明,GA-ELM 能够较好地

ELM 在测试集上的分类诊断结果以及不同缺陷类型的查全率. 其中,“破裂”的管道样本 62 条,GA-ELM 诊断模型准确预测 48 条,查全率 77.42%;“脱节”的管道样本 48 条,准确预测 36 条,查全率为 75.00%;“渗漏”的管道样本 89 条,准确预测 68 条,查全率为 76.40%. ELM 诊断模型对于上述 3 类缺陷管道的查全率则分别为 59.68%、52.08% 和 65.17%. 可见,相比 ELM,GA-ELM 诊断模型对于缺陷管段的识别能力更强,具有更优的分类预测性能. 不过,由表 3 结果也发现,两个模型对“正常”管段的识别能力均高于其他缺陷管段,这估计与实验区排水管道样本的非均衡分布有关.

对排水管道结构性缺陷进行诊断识别,且分类精度可较好满足应用要求.




图 5 GA-ELM 分类诊断结果

Fig. 5 Contrast between predicted results and observed results of GA-ELM

3 结 论

1)提出了基于 GA-ELM 的排水管道缺陷诊断模型,采用 GA 算法优化 ELM 神经网络输入连接权值和隐含层偏置,避免参数随机初始化造成的分类结果不稳定、准确率偏低的弊端.

2)利用 CCTV 检测样本集对 GA-ELM、ELM 进行仿真测试,结果表明,在采用同样的激励函数和隐含层节点数的条件下,通过 GA 优化 ELM 网络参数能够获得更高的分类诊断性能,测试集分类精度由 65.59% 提高到 82.96%;参数优化提高了 ELM 模型的拟合能力和稳定性.

3) 本文为城市排水管道缺陷识别和诊断提供了一个新型的数据驱动建模方法, 具有较好的可行性和适用性。后续将收集更多的样本数据训练优化模型, 并探讨非均衡样本对缺陷诊断性能的影响, 进一步提高排水管道缺陷诊断模型的预测精度和泛化能力。

参考文献

- [1] 中华人民共和国住房和城乡建设部. 城镇排水管道检测与评估技术规程: CJJ 181—2012[S]. 北京: 中国建筑工业出版社, 2012
- Ministry of Housing and Urban-Rural Development of the People's Republic of China. Technical specification for inspection and evaluation of urban sewer: CJJ 181—2012[S]. Beijing: China Architecture & Building Press, 2012
- [2] MICEVSKI T, KUCZERA G, COOMBES P. Markov model for storm water pipe deterioration[J]. Journal of Infrastructure Systems, 2002, 8(2): 49. DOI:10.1061/(ASCE)1076-0342(2002)8:2(49)
- [3] 刘威, 李杰. 埋地管线面积腐蚀率概率密度的模拟分析[J]. 同济大学学报(自然科学版), 2007, 35(10): 1295
- LIU Wei, LI Jie. Simulation analysis for probability density of buried pipeline's area corrosion ratio[J]. Journal of Tongji University (Natural Science), 2007, 35(10): 1295. DOI:10.3321/j.issn:0253-374X.2007.10.001
- [4] MASHFORD J, MARLOW D, TRAN D, et al. Prediction of sewer condition grade using support vector machines[J]. Journal of Computing in Civil Engineering, 2011, 25(4): 283. DOI:10.1061/(ASCE)CP.1943-5487.0000089
- [5] HARVEY R R, MCBEAN E A. Predicting the structural condition of individual sanitary sewer pipes with random forests[J]. Canadian Journal of Civil Engineering, 2014, 41(4): 294. DOI:10.1139/cjce-2013-0431
- [6] TRAN D H, NG A W M, PERERA B J C, et al. Application of probabilistic neural networks in modelling structural deterioration of stormwater pipes[J]. Urban Water Journal, 2006, 3(3): 175. DOI:10.1080/15730620600961684
- [7] TRAN D H, NG A W M, PERERA B J C. Neural networks deterioration models for serviceability condition of buried stormwater pipes[J]. Engineering Applications of Artificial Intelligence, 2007, 20(8): 1144. DOI:10.1016/j.engappai.2007.02.005
- [8] TRAN D H, PERERA B J C, NG A W M. Comparison of structural deterioration models for stormwater drainage pipes[J]. Computer-Aided Civil and Infrastructure Engineering, 2009, 24(2): 145. DOI:10.1111/j.1467-8667.2008.00577.x
- [9] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489. DOI:10.1016/j.neucom.2005.12.126
- [10] WANG Yuguang, CAO Feilong, YUAN Yubo. A study on effectiveness of extreme learning machine[J]. Neurocomputing, 2011, 74(16): 2483. DOI:10.1016/j.neucom.2010.11.030
- [11] HOLLAND J H. Adaptation in natural and artificial systems[J]. Ann Arbor, 1975, 6(2): 126
- [12] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics Part B: Cybernetics, 2012, 42(2): 513. DOI:10.1109/tsmcb.2011.2168604
- [13] ANA E, BAUWENS W, PESSEMIER M, et al. An investigation of the factors influencing sewer structural deterioration[J]. Urban Water Journal, 2009, 6(4): 303. DOI:10.1080/15730620902810902
- [14] HARVEY R R, MCBEAN E A. Comparing the utility of decision trees and support vector machines when planning inspections of linear sewer infrastructure[J]. Journal of Hydroinformatics, 2014, 16(6): 1265. DOI:10.2166/hydro.2014.007

(编辑 刘 彤)