



移动扫码阅读

王渲,田文翀.基于支持向量机的城市道路降雨径流污染预测模型[J].能源环境保护,2020,34(2):92-98.
WANG Xuan, TIAN Wenchong. Pollution prediction model for urban road rainfall runoff based on support vector machine[J]. Energy Environmental Protection, 2020, 34(2): 92-98.

基于支持向量机的城市道路降雨径流污染预测模型

王 渲, 田文翀

(同济大学 环境科学与工程学院, 上海 200092)

摘要:为实现城市降雨径流污染有效预测,以文献中的实测数据作为样本,选取雨型、平均雨强、峰值雨强、降雨历时、雨前干期、大气降尘量、 PM_{10} 、车流量、路面材料及城市功能区等10项影响因素作为模型输入量,选取径流污染指标COD的场次降雨平均浓度EMC及初期冲刷指数FF30作为模型输出量,基于支持向量机(SVM)构建了城市道路径流污染预测模型。结果表明:EMC-SVM及FF30-SVM模型均具有较高的预测精度,EMC-SVM模型校验参数RMSE、MBE远小于数据集EMC均值,CE、CC达到0.815及0.933;FF30-SVM模型校验参数RMSE、MBE远小于数据集FF30均值,CE、CC分别为0.866及0.932;选用径向基函数(RBF)作为核函数,使用k折交叉验证法对模型参数进行寻优,对于EMC-SVM及FF30-SVM模型寻得的最优参数(c,g)分别为(64.0,0.001 953 125)、(2.0,0.062 5)。

关键词:降雨径流污染;EMC;初期冲刷;统计学习;支持向量机

中图分类号:X32

文献标识码:A

文章编号:1006-8759(2020)02-0092-07

Pollution prediction model for urban road rainfall runoff based on support vector machine

WANG Xuan, TIAN Wenchong

(College of Environmental Science and Engineering, Tongji University, Shanghai 200092, China)

Abstract: In order to effectively predict urban rainfall runoff pollution, a road runoff pollution prediction model was built based on support vector machine (SVM) taking the data in previous literatures as sample. This model selected 10 influence factors (rain type, average rain intensity, peak rain intensity, rainfall duration, dry period before rain, atmospheric dust amount, PM_{10} , vehicle flow, surface material and urban functional area) as the model inputs, and selected event mean concentration (EMC) and first flush index FF30 as the model outputs. The results show that: ① Both EMC-SVM and FF30-SVM models have high prediction accuracy. The calibration parameters (RMSE and MBE) of EMC-SVM model are much lower than the average EMC. The CE and CC of EMC-SVM model are 0.815 and 0.933, respectively. The calibration parameters (RMSE and MBE) of FF30-SVM model are much lower than the average FF30, The CE and CC of FF30-SVM model are 0.866 and 0.932, respectively. ② Using radial basis function (RBF) as the kernel function and the k-folding cross validations as the validation method, the optimal parameters of EMC-SVM and FF30-SVM models are found to be (64.0, 0.001 953 125) and (2.0, 0.062 5), respectively.

Key Words: Rainfall runoff pollution; EMC; First flush; Statistical learning; Support vector machine

收稿日期:2019-09-05

基金项目:国家重点研发计划政府间国际科技创新合作重点专项(2016YFE0123300);国家自然科学基金(No.51578396);国家自然科学基金(No.51778451)

第一作者简介:王渲(1993-),女,甘肃庆阳人,博士研究生在读,主要从事水环境模型及其优化应用研究。E-mail: wxuan@tongji.edu.cn

0 引言

城市降雨径流污染是指降雨径流水体对累积在城市路面、屋顶、绿地等不同下垫面的污染物质(如 SS、原油、氮、磷、重金属、有机物质等)形成淋溶、冲刷作用,并将其裹挟的污染物通过排水系统直接排入受纳水体而造成的水体面源污染现象^[1]。城市的发展极大地增加了建筑物和硬化道路的比例,改变了天然状态下雨水的产汇流规律,使得降雨时形成了更多地表径流。其结果会导致城市水体水质和生态系统受到破坏,产生包括富营养化、水环境恶化、水体黑臭等众多问题,影响城市水环境健康与水生态安全。

借助于降雨径流模型对径流污染进行预测,是控制城市降雨径流污染的主要途径之一。由于水质问题受多因素影响及其复杂性,许多生物、化学过程的反应机理尚未能通过模型进行描述。同时,水质机理模型在应用过程中通常需要大量的水文、水质参数,而这些参数既多又难于测量,这些都限制了确定性水质数学模型的适用性和准确性^[2-3],机器学习直接从实测数据出发挖掘水质模型的内在规律为国内外学者提供了另一种研究思路。

在城市水质研究中: MJ Rodriguez^[4]提出人工神经网络模型,从另一个角度研究了余氯在配水系统中的衰减,并与传统的一级模型进行了对比。模型是通过算法和使用一个时间延迟输入拓扑结构实现的,对两个供水系统进行的模拟表明在水温较低时一级模型显示了较好的效果,而在水温较高时模型则显示了较好的预测。杨航等^[5]基于神经网络建立了复杂管网余氯水质预测模型,该方法避开复杂的管网水力计算,以实际测定参数进行训练和验证,具有较好精度。李芸^[6]等针对当前非点源污染中雨水径流水质监测数据匮乏而难以评估其污染负荷的弊端,将 BP 神经网络模型引入评估雨水径流污染负荷问题。在湖泊水质研究中:徐红敏^[7]通过建立支持向量机水质参数评价模型来预测太湖高锰酸盐月平均浓度取得了良好的效果。Recknagel^[8]等系统地研究了 ANN 模型在水质预测中的应用,建立了三个淡水湖泊预测藻类暴发的 ANN 模型和一个河流预测藻类暴发的 ANN 模型,预测结果表明,模型可以预测不同环境条件下淡水水体中像藻类暴发这样复杂的和非线性的水环境现象。胡明星^[9]等提出了基于

多准则学习的模糊神经网络湖泊水质营养化评价模型。在河道水质研究中: HR. Maier^[10]和 GC. Dandy 对澳大利亚南部 Murray 河上某段的水质参数矿化度进行了预测,取得了一定成效。王里奥^[11]等利用因子分析法找出影响南渡河水质的主要污染指标,建立了基于 BP 神经网络的主要污染指标预测模型对近几年的主要污染因子进行了预测。HM Nagy 等^[12]建立了神经网络模型预测河流沉积负荷的浓度。但是,将机器学习方法应用于降雨径流水质污染的研究鲜有:田欢^[6]基于 BP 神经网络构建了雨水径流污染物总量评估模型,并应用 Schueler 公式对评估结果进行验证。

本文考虑到降雨径流污染的非线性、多影响因素特点,通过对文献中获得的不同地域的大量实测数据进行挖掘,建立支持向量机(SVM)的城市降雨径流预测模型,对场次降雨平均浓度 EMC 及初期冲刷指数 FF30 进行预测。研究方法及预测结果能够为降雨径流污染的有效控制提供参考及数据支撑。

1 理论基础

1.1 场次降雨径流污染平均浓度(EMC)

城市降雨径流污染物浓度规律可由瞬时浓度及平均浓度 EMC 共同表征。其中,瞬时浓度反映污染物浓度的动态变化情况,是进一步获得场次降雨污染物浓度的极大值、极小值、平均值及其变化规律的重要指标,同时也为初期冲刷效应的判别和的计算提供基础数据,需要通过连续测量获得。

然而,由于降雨特征的随机性,路面沉积物的非均质性以及雨期污染源排放污染物的随机性,在场次降雨径流过程中污染物瞬时浓度在较大范围内变化。因此,USEPA 结合 NURP 计划研究成果,建议以参数 EMC(Event Mean Concentration)来表征径流污染强度,因为从暴雨径流对受纳水体的影响方面来看,水体对排入的地表径流的污染响应速度相对径流过程中污染物瞬时浓度变化而言要慢得多。此后,国内外研究均采用该指标表征场次径流污染物的浓度。EMC 可由式(1)计算:

$$EMC = \frac{M(T)}{V(T)} = \frac{\int_0^T C_t Q_t}{\int_0^T Q_t} \quad (1)$$

式中:

$M(T)$ ——场次降雨累积污染物总量,mg;

$V(T)$ ——场次降雨累积径流总量,L;

C_i ——瞬时径流污染浓度,mg/L;

Q_i ——瞬时径流量,L/min;

T ——降雨径流事件总时间,min。

1.2 初期冲刷指数

初期冲刷效应是指在初期降雨径流过程中污染物浓度明显高于后期径流冲刷的污染物浓度^[13]。由于初期冲刷效应受到城市污染物累积过程、降雨径流过程以及两者相互作用影响,在不同汇水区域,或者同一汇水区域的不同场次降雨的初期冲刷程度均不相同。降雨特征、汇水区域特征等是影响初期冲刷效应程度的主要因素。由于不同地区的气候、降雨特征等存在差异,影响道路径流污染物的因素也不相同,因此需要根据当地特点具体分析。

通常采用无量纲累积分析 $M(V)$ 曲线图评价初期冲刷效应存在与否^[14]。降雨径流过程中的累积污染负荷比例 M 与累积径流量比例 V 计算方法如式(2)和式(3)所示。

$$M = \frac{M(t)}{M(T)} = \frac{\sum_0^t C_i Q_i \Delta t}{\sum_0^T C_i Q_i \Delta t} \quad (2)$$

$$V = \frac{V(t)}{V(T)} = \frac{\sum_0^t Q_i \Delta t}{\sum_0^T Q_i \Delta t} \quad (3)$$

式中:

$M(t)$ —— t 时刻累积污染物总量,mg;

$V(t)$ —— t 时刻累积径流量,L;

$M(T)$ ——场次降雨累积污染物总量,mg;

$V(T)$ ——场次降雨累积径流总量,L;

C_i ——瞬时径流污染浓度,mg/L;

Q_i ——瞬时径流量,L/min;

Δt ——连续测定时间间隔,min;

T ——降雨径流事件总时间,min。

本研究中为了量化初期冲刷效应,并为后续预测模型的建立定义预测变量,引入了初期冲刷指数的概念,定义场次降雨累积径流量比例为30%时所对应的累积污染负荷比例为FF30,即 $M(V)$ 曲线上 $V=0.3$ 所对应的 M 的值。

1.3 支持向量机

支持向量机(SVM)由 Vapnik 及 Cortes 等人在 1995 年率先提出^[15],通过寻求结构风险最小

化来实现置信范围及经验风险最小化目标,这使其能够在样本量较少的情况下获得良好的统计规律,并在处理非线性及高维模式识别问题时具有特有的优势。

支持向量机算法由对线性可分数据集进行分类的最优超平面概念发展而来,简单地说,就是运用机器学习寻找对线性或非线性数据进行分类的最优分类面,而最优分类面的确定是由少数样本点决定,即支持向量(Support Vector,SV)。在运算时,与分类超平面无关的样本点被剔除,只保留作为支持向量的样本点,从而大幅提高运算效率(图1)。




图1 最优分类超平面示意图

支持向量回归模型的目标是对训练样本集,找到一个参数对 (w, b) 使得函数 $f(x_i) = (w, x_i) + b$ 和实际获得的目标 y_i 之间有尽量小的偏差,与此同时还要做的让它尽可能的平滑,即使 w 的范数 $\|w\|$ 最小。同时考虑超出精度的拟合误差,创造松弛变量 ξ_i, ξ_i^* 。改写成凸规划问题:

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s.t.} \quad & y_i - (w, x_i) - b \leq \varepsilon + \xi_i \\ & (w, x_i) + b - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \end{aligned} \quad (4)$$

式中:

$(x_i, y_i), i=1, 2, \dots, n, x \in R^d$ ——训练样本集;

w —— n 维维向量;

b ——偏移量;

C ——正常数,用于平衡 f 的平滑性和所被允许的超过 ε 的误差之和的作用。

2 基于支持向量机的城市道路降雨径流预测模型训练及验证

2.1 数据来源

机器统计学习需要一定规模的样本量。为了获得具有代表性、质量较高的足量样本集,本研究广泛检索研究城市降雨径流污染的国内外学位论文

文,从实验方法、研究区域、研究结论等多方面综合分析,获取满足 SVM 模型训练要求的样本数据。由于国内外对于城市降雨径流污染的实验研究多以道路作为研究对象,因此本研究预测模型亦针对道路径流建立。表 1 所示为本章预测模型研究数据来源。

表 1 道路径流污染模型数据来源

编号	作者	城市	年份	测试径流场次 ^a
1	王和意 ^[16]	上海	2004	6
2	王业雷 ^[17]	南昌	2007~2008	9
3	毛彦景 ^[18]	重庆	2009	3
4	陈莹 ^[1]	西安	2009	36
5	郝丽玲 ^[19]	重庆	2010~2011	13
6	汉京超 ^[20]	福州	2011~2012	17
7	陈子宇 ^[21]	广州	2012	4
8	蒋沂孜 ^[22]	深圳	2012	7
9	宋迁凤 ^[23]	重庆	2011~2012	7
10	田欢 ^[24]	深圳	2014	4
11	袁艳 ^[25]	苏州	2014	12
12	王昭 ^[26]	西安	2014~2015	13
13	王渲	武汉	2017	4

注:a.在同一场次降雨下对两处不同道路路面进行径流污染测试计作 2 次。

2.2 影响因子及决策变量

结合国内外对于降雨径流污染影响因素的研究成果,道路降雨径流污染主要受降雨特征、大气污染情况、交通流量及其他城市功能区等因素的影响。概括得出模型影响因子(输入值)见列表 2。

预测模型的决策变量(输出量)应当能够综合反映场次降雨径流污染特征,包括径流污染程度及初期冲刷效应等特性,此外,由于 COD 是评价降雨径流污染程度及控制情况的重要指标,因此选取指标 COD 的场次降雨径流污染平均浓度 EMC 及初期冲刷指数 FF30 值作为评估模型的决策变量(输出量)。

表 2 影响因子

编号	影响因子	单位
X1	雨型	—
X2	平均雨强	mm/h
X3	峰值雨强	mm/h
X4	降雨历时	min
X5	雨前干期	h
X6	大气降尘量	t/km ² ·月

续表

编号	影响因子	单位
X7	PM ₁₀	mg/m ³
X8	车流量	辆/h
X9	路面材料	—
X10	功能区	—

确定模型所需数据样本的输入量(影响因子)及输出量(决策变量)之后,通过从文献直接获取、检索及调研等方式,补齐所选取数据集的影响因子。由于 SVM 模型在预测新样本时不允许缺失值存在,因此对于无法补齐缺失信息的数据采取剔除处理。经过数据清洗得到的数据集样本量见表 3。

表 3 数据集样本量

数据集	训练样本量	验证样本量
EMC	45	20
FF30	45	20

2.2.1 非数值影响因子

支持向量机(SVM)要求被处理的数据均为实数。表 2 中所示 10 项影响因子中,平均雨强、峰值雨强、降雨历时、雨前干期、大气降尘量、PM₁₀、车流量等均为数值型变量,可直接进行标准化处理之后进入模型运算;而对于非数值属性雨型、路面材料及功能区,参考文献资料,作如下进一步转换。

(1)雨型:定义为类别型变量,并将其划分为峰值靠前、居中及靠后三类,分别对应编码{1,0,-1}。

(2)路面材料:将道路路面材料归纳为沥青及水泥混凝土两类,分别对应编码{1,0}。

(3)城市功能区:本研究按照数据集各研究区域人口密度、道路清扫频次及空气污染等要素进行赋权重值打分,要素权重见表 4,分值范围均为 0~100。打分标准为:人口密度越大、清扫频次越低、空气污染程度越差,则分值越高;其他项考虑不同实测点导致径流污染加重的相关因素。各项得分加权平均即得到“功能区”影响因素的数值。

表 4 功能区评价要素权重

要素	人口密度	清扫频次	空气污染程度	其他
权重	0.3	0.3	0.2	0.2

2.2.2 数据标准化

表 2 所示影响因子及决策变量具有不同的量纲及量纲单位,其数值大小会使得模型运算时产

生不同的权重影响,导致模型收敛速度降低、数据分析结果失真。在支持向量机模型中,径向基核函数 RBF 采用样本数据的欧式距离计算,能够避免数值较大的变量控制数值较小的变量,但是较大的数值差距会影响模型计算,降低模型收敛速度。因此,为了消除变量间的量纲影响,对数据进行 Z-score 标准化(Z-score Normalization)处理,使得不同变量之间具有可比性:

$$x^* = \frac{x - \mu}{\sigma} \quad (5)$$

式中:

μ ——样本均值,

σ ——样本标准差。

2.3 道路降雨径流污染 SVM 模型建立

2.3.1 核函数选择

在支持向量机预测建模的过程中核函数尤为重要,直接关系到最后预测数据的准确性。本文通过多次实验确定以径向基函数 RBF 作为核函数,预测模型的性能最好。

2.3.2 模型参数选择

SVM 确定采用径向基核函数后,参数的选择目标为寻找一组能使预测模型准确率最高的惩罚因子 c 和核参数 g 。其中,惩罚因子 c 决定了模型重视离群点引入的损失程度;而核参数 g 决定模型的泛化能力。本文支持向量机参数的选择采用网格搜索法,使用 Python 工具包 gridgression 提供的 k 折交叉验证法对径向基核函数的 c 、 g 参数进行寻优,搜索范围和搜索步长分别为 $[-10, 10]$ 及 1。对于 EMC 和 FF30 模型寻得的最优参数见表 5 所示。

表 5 径向基核函数最优参数

数据集	c	g
EMC	64.0	0.001 953 125
FF30	2.0	0.062 5

2.4 模型校核及验证

2.4.1 校验参数

基于下述 4 类参数对 SVM 回归模型结果进行校验:

(1)均方根误差(The root mean square error, RMSE):

$$RMSE = \sqrt{\frac{1}{n-1} \sum_{k=1}^n (Y_{SVM} - Y)^2} \quad (6)$$

式中:

Y_{SVM} ——EMC 及 FF30 的 SVM 模型预测值;

Y ——数据集 EMC 及 FF30 实验值。

均方根误差 RMSE 反映模型预测值及实测值之间的标准偏差,其值越小表明模型预测精度越高。

(2)平均偏差(The mean bias error, MBE):

$$MBE = \frac{1}{n} \sum_{k=1}^n (Y_{SVM} - Y) \quad (7)$$

平均偏差 MBE 反映模型预测值与实测值之间的平均误差,具有一定的参考意义。

(3)效率系数(Coefficient Efficiency, CE):

$$CE = 1 - \frac{\sum_{k=1}^n (Y - Y_{SVM})^2}{\sum_{k=1}^n (Y - \bar{Y})^2} \quad (8)$$

式中:

\bar{Y} ——数据集决策变量 EMC 或 FF30 的平均值。

效率系数 CE 广泛应用于校验水文水力模型的模拟性能,反映模型预测值与实测值之间的方差与实测值均方差的比值,其值越接近于 1 表明模型预测精度越高。

(4)相关系数(Correlation coefficient, CC):

$$CC = \frac{\sum_{k=1}^n (Y - \bar{Y})(Y_{SVM} - \bar{Y}_{SVM})}{\sqrt{\sum_{k=1}^n (Y - \bar{Y})^2} \sqrt{\sum_{k=1}^n (Y_{SVM} - \bar{Y}_{SVM})^2}} \quad (9)$$

式中:

\bar{Y}_{SVM} ——模型预测值 EMC 或 FF30 的平均值。

相关系数反映模型预测值与实测值之间的相关性,其值越接近于 1,表明模型预测精度越高。

2.4.2 校验结果

使用 libsvm 工具包提供的 Java 接口分别对两组数据集进行训练,运用验证样本对模型进行验证。图 2 及图 3 所示分别为径流污染 COD 指标的 EMC 及 FF30 模型预测值与实测值对比,由图可知基于两组数据集训练得到的 SVM 模型均具有较好的预测能力。




图2 EMC 实测值及模型预测值对比




图3 FF30 实测值及模型预测值对比

表6 EMC-SVM 模型校验参数

	样本数	RMSE	MBE	CE	CC
训练样本	45	69.546	-45.628	0.829	0.920
验证样本	20	57.928	-1.231	0.815	0.933

表7 FF30-SVM 模型校验参数

	样本数	RMSE	MBE	CE	CC
训练样本	45	0.060	0.008	0.841	0.931
验证样本	20	0.038	0.004	0.866	0.932

表6及7所示分别为EMC及FF30支持向量机模型的校验参数,从对验证样本的预测结果看,EMC-SVM模型均方根误差(RMSE)、平均偏差(MBE)分别为57.928及-1.231,远小于数据集EMC均值(189.59 mg/L),其效率系数(CE)及相关系数(CC)分别达到0.815及0.933,表明该模型具有较高的预测精度;FF30-SVM模型均方根误差(RMSE)、平均偏差(MBE)分别为0.038及0.004,远小于数据集FF30均值(0.457),其效率系数(CE)及相关系数(CC)分别为0.866及0.932,表明FF30-SVM模型同样具有较高的预测精度。

3 结果及讨论

论文以前人文献中的实测数据作为样本,结

合国内外研究成果及论文实验部分研究结论,选取合适的影响因子及决策变量作为模型输入量及输出量,基于支持向量机(SVM)构建了道路径流污染预测模型。主要结论如下:

(1)选取雨型、平均雨强、峰值雨强、降雨历时、雨前干期、大气降尘量、PM₁₀、车流量、路面材料及城市功能区等10项影响因子作为模型输入量,分别选取径流污染指标COD的场次降雨EMC及FF30值作为模型输出量。对非数值属性雨型、路面材料按类别编码进行转换,对城市功能区采用按要素权重打分的转换方法。

(2)选用径向基函数(RBF)作为核函数,使用k折交叉验证法对模型参数进行寻优,对于EMC-SVM及FF30-SVM模型寻得的最优参数(c,g)分别为(64.0,0.001 953 125)、(2.0,0.062 5)。

(3)校验结果表明论文构建的EMC-SVM及FF30-SVM模型均具有较高的预测精度。EMC-SVM模型校验参数RMSE、MBE远小于数据集EMC均值,CE、CC达到0.815及0.933;FF30-SVM模型校验参数RMSE、MBE远小于数据集FF30均值,CE、CC分别为0.866及0.932。

此外,本文建立的预测模型以国内多个城市的道路降雨径流污染实测数据为样本,通过验证,该模型预测精度较高,因此可作下述应用:

(1)对于开展监测实验难度较大的城市道路,可以运用该模型进行降雨径流污染的预测和评估;通过道路特性参数及降雨特性参数的输入得到其在特定场次降雨下的EMC及FF30输出值。

(2)预测模型输出值EMC可作为降雨径流模型(如:SWMM)的输入参数,通过模型进一步计算出排水管网出口污染负荷。

(3)低影响开发(LID)作为城市降雨径流水质水量管理的重要途径,其方案设计应基于可靠的场地基础数据。降雨径流形成后,先经过LID单体设施的消纳及净化,再进入管网系统排出。因此路面径流污染预测值EMC及FF30可作为LID方案设计的基础数据。同时,模型输出值FF30反映初期冲刷效应的显著性,可为初雨截留装置的设计提供依据。

(4)通过累加特定道路一年内所有场次降雨的EMC预测值与径流量的乘积,得到道路年径流污染负荷评估值。

参考文献

- [1] 陈莹. 西安市路面径流污染特征及控制技术[D]. 西安: 长安大学, 2011: 10-30.
- [2] HUANG W, FOO S. Neural network modeling of salinity variation in Apalachicola River [J]. Water Research, 2002, 36 (1): 356-362.
- [3] 汪家权, 陈众, 武君. 河流水质模型及其发展趋势 [J]. 安徽师范大学学报(自科版), 2004, 27 (3): 242-247.
- [4] RODRIGUEZ M J, WEST J R, POWELL J, et al. Application of two approaches to model chlorine residuals in severn trent water ltd (STW) distribution systems [J]. Water Science & Technology, 1997, 36 (5): 317-324.
- [5] 杨航, 李敏, 俞国平. 基于人工神经网络的市政管网水质模型研究 [J]. 给水排水, 2012 (s1): 471-475.
- [6] 李芸, 田欢, 张明顺, 等. 基于BP神经网络的雨水径流污染负荷评估模型 [J]. 中国农村水利水电, 2017 (3): 68-74.
- [7] 徐红敏. 基于支持向量机理论的水环境质量预测与评价方法研究 [D]. 长春: 吉林大学, 2007: 22-38.
- [8] RECKNAGEL F, FRENCH M, HARKONEN P, et al. Artificial neural network approach for modelling and prediction of algal blooms [J]. Ecological Modelling, 1997, 96 (1-3): 11-28.
- [9] 胡明星, 郭达志. 湖泊水质富营养化评价的模糊神经网络方法 [J]. 环境科学研究, 1998, 11 (4): 40-42.
- [10] MAIERHR, DANDYGC. Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications [J]. Environmental Modelling & Software, 2000, 15 (1): 101-124.
- [11] 王里奥, 任家宽, 刘阳生, 等. 基于因子-神经网络预测南渡江海口段水质状况 [J]. 环境科学与管理, 2008, 33 (6): 176-179.
- [12] NAGY H M, WATANABE K, HIRANO M. Prediction of sediment load concentration in rivers using artificial neural network model [J]. Journal of Hydraulic Engineering, 2002, 14 (1): 588-595.
- [13] GUPTA K, SAUL A J. Specific relationships for the first flush load in combined sewer flows [J]. Water Research, 1996, 30 (5): 1244-1252.
- [14] HELSEL D R, KIM J I, GRIZZARD T J, et al. Land use influences on metals in storm drainage [J]. Journal (Water Pollution Control Federation), 1979, 51 (4): 709-717.
- [15] CORTES C, VAPNIK V. Support-vector networks [J]. Machine Learning, 1995, 20 (3): 273-297.
- [16] 王和意. 上海城市降雨径流污染过程及管理措施研究 [D]. 上海: 华东师范大学, 2005: 273-297.
- [17] 王业雷. 南昌市中心区降雨径流污染过程与防治措施研究 [D]. 南昌: 南昌大学, 2008: 45-50.
- [18] 毛彦景. 重庆地区高速公路路面径流污染特征研究 [D]. 重庆: 西南大学, 2010: 43-52.
- [19] 郝丽岭. 重庆城市居民区不同下垫面降雨径流污染及其控制研究 [D]. 重庆: 西南大学, 2012: 55-60.
- [20] 汉京超. 城市雨水径流污染特征及排水系统模拟优化研究 [D]. 上海: 复旦大学, 2013: 66-78.
- [21] 陈子宇. 广州市校园区降雨径流污染特征研究 [D]. 广州: 华南理工大学, 2013: 46-55.
- [22] 蒋沂孜. 雨水花园对华南地区城市道路路面源污染控制研究 [D]. 北京: 清华大学, 2014: 58-74.
- [23] 宋迁凤. 重庆市某城区地表降雨径流污染特征研究 [D]. 重庆: 重庆大学, 2012: 43-50.
- [24] 田欢. 雨水径流污染物总量的计测及其评估方法研究 [D]. 北京: 北京建筑大学, 2016: 52-57.
- [25] 袁艳. 苏州城区路面降雨径流污染特征及控制措施研究 [D]. 苏州: 苏州科技学院, 2015: 45-57.
- [26] 王昭. 西安市路面径流污染排放特征 [D]. 西安: 长安大学, 2016: 35-58.