

doi:10.11835/j.issn.2096-6717.2019.084



PSO-SVM 与 BP 神经网络组合预测供水系统 余氯的方法

毛湘云,徐冰峰,孟繁艺

(昆明理工大学 建筑工程学院,昆明 650500)

摘要:针对余氯量在供水系统内非线性变化的特性,建立了 PSO-SVM 与 BP 神经网络组合模型对管网末端余氯进行预测分析。该模型通过粒子群优化算法(PSO),对 SVM 的特性参数进行优化;采用 BP 神经网络对模型进行残差修正。通过对单一的 BP 模型和 SVM 模型、组合模型的预测精度进行分析。结果表明:组合模型预测比 BP 和 SVM 单一预测均方误差分别降低了 62.30%、75.29%,平均相对误差降低了 55.03%、54.27%。综上所述,该模型具有强大的非线性拟合能力,预测精度高,运行稳定性强,对供水企业控制余氯的投加量和设置二次加氯点有一定的指导作用。

关键词:余氯;支持向量机;粒子群算法;神经网络;组合模型

中图分类号:TU991.33 文献标志码:A 文章编号:2096-6717(2019)04-0159-06

Prediction of residual chlorine in water supply system by PSO-SVM and BP neural network combined model

Mao Xiangyun, Xu Bingfeng, Meng Fanyi

(Faculty of Civil Engineering and Mechanics, Kunming University of Science and Technology, Kunming 650500, P. R. China)

Abstract: Due to the nonlinearity of residual chlorine in the pipe network, a PSO-SVM and BP neural network combined model was developed to prediction of residual chlorine. This model through particle swarm optimization algorithm (PSO) to optimization the characteristics parameter of the SVM, and use the BP neural network model to residual error correction. The prediction precision of combined model was analysed by comparing the single prediction model of BP and SVM. The results show that compared with the single prediction of BP and SVM, the mean square error of the combined model decreased by 62.30% and 75.29% respectively, but the average relative error decreased by 55.03% and 54.27% respectively. In a conclusion, the combined model had strong nonlinear fitting capability, high prediction accuracy, and strong operation stability. This model plays an important role in controlling the residual chlorine dosing and setting the secondary chlorination point for water supply enterprise.

Keywords: residual chlorine; support vector machines; particle swarm optimization; neural networks; combined model

收稿日期:2018-11-24

作者简介:毛湘云(1994-),女,主要从事市政工程研究,E-mail:1169005203@qq.com。

徐冰峰(通信作者),女,副教授,E-mail:xbf321@sina.com。

Received:2018-11-24

Author brief: Mao Xiangyun (1994-), main research interest: municipal engineering, E-mail:1169005203@qq.com.

Xu Bingfeng(corresponding author), associate professor, E-mail:xbf321@sina.com.

氯是供水处理中使用最广泛的一种消毒剂,余氯作为衡量管网水质的一项重要指标,对控制水中的细菌滋生,保证管网水质安全十分重要。《生活饮用水卫生标准》(GB 5749—2006)^[1]中规定,出厂水余氯应大于 0.3 mg/L,管网末梢余氯量不应小于 0.05 mg/L。但由于氯是一种非稳定性物质,受到管网中各种因素的影响,其浓度随时间的推移而发生削减,消毒能力下降,使得水质发生恶化,水质保障的中心已逐渐由水厂向管网转移^[2-4]。所以探究余氯预测方法,为供水企业对氯的投加提供参考十分重要^[5]。

由于余氯浓度在管网中的削减是非线性变化,且管网内影响余氯的因素众多,若采用机理性模型进行预测,其准确性差,建立难度大,求解困难^[6-7]。目前已有研究多采用单一网络或复合网络对余氯进行预测,加之分析样本有限,预测后没有对结果进行误差修正,且随着样本量的增加,预测精度也随之下降,网络的精确性、收敛性及稳定性不好,难以获得理想的预测结果^[5,8-9]。本文通过 PSO-SVM+BP 神经网络余氯预测模型,建立多个影响因素与管网末端余氯映射关系,以了解余氯的衰减规律,实现对余氯浓度的动态预测。

1 PSO-SVM 与 BP 神经网络组合模型

支持向量机(Support Vector Machine)是基于统计学理论发展起来的机器学习算法^[5]。它以结构风险最小化原则为理论基础,引入核函数方法,将原始问题映射到高维空间,把待求解问题转换为二次优化问题,使 SVM 收敛于问题的全局最优解。它能较好地解决小样本、非线性、高维数和局部极小点等实际问题,具有良好的泛化能力^[10-12]。但 SVM 中关键参数(核函数参数、惩罚因子 C)的选取多依靠经验或实验,而这些参数对预测的结果有至关重要的影响^[13]。所以,针对 SVM 参数选取的盲目性,采用粒子群算法(PSO)对 SVM 进行参数优化,以 SVM 输出的均方误差为适应度函数,粒子通过跟踪个体极值和全局极值在空间内不断更新自己的位置信息、迁移方向和速度值,以寻找出空间内的最优解,即输出 SVM 最小均方误差时带入的参数粒子^[14],消除 SVM 参数选取的盲目性,但 PSO 算法后期收敛到一定程度时就无法继续优化,所以精度不高。为提高精度,利用 BP 神经网络较高的可靠性和良好的容错性,获得输入变量与优化模型预测

误差之间的映射关系,建立 BP 神经网络残差修正模型^[15-17]。最终通过两个模型的组合进行优势互补,深度挖掘数据信息,以获得更理想的预测结果,提高预测精度。

2 组合算法模型的建立

2.1 数据的筛选与处理

由于管网内余氯浓度成非线性变化,管网末端的余氯浓度,受到多种因素的影响。供水管网中余氯浓度主要受到上游监测点出厂水的余氯浓度、浊度、管网输配时间、管道内的腐蚀程度、PH 值、管网材料和细菌总数的影响^[18-22]。所以,从模型的普适性和对水厂的实地调研考虑^[23],取滇南某水厂 2017 年 1 月—12 月份的水质检测数据,构建余氯预测模型,确定出厂水余氯浓度、PH 值及浊度为影响因子,研究影响因子与管网末端余氯浓度之间的映射关系。

对某水厂的 187 个数据样本进行随机排列,取不同的组合方式对模型进行训练,最终确定将数据分为 2 部分,85% 的数据作为训练数据,均分为各含有 80 个数据,分别建立 PSO-SVM 模型和 BP 残差模型;剩下的 27 个数据作为验证数据,进行交叉验证,以验证组合模型精度。末端取样点距离水厂的直线距离为 2.4 km,末端余氯浓度范围为 0.02~0.06 mg/L,每个样本内都含有出厂余氯浓度、pH 值、浊度及管网末端取样点余氯浓度。由于数据指标不相同,数量级有一定的差别,为方便计算,需要对样本数据进行归一化处理,使数据值都归一至 [0,1] 之间,归一化公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

2.2 SVM 模型的建立及优化

2.2.1 SVM 模型的建立 将第 1 组归一化后的出厂水的余氯浓度、pH 值及浊度设为输入值,管网末端出水余氯浓度作为输出值,输入到 SVM 模型内进行训练。首先,通过高斯径向核函数 $\varphi(x)$,将训练集 x_i 映射到高维线性空间,构造回归估计函数

$$f(x) = \omega \varphi(x) + b \quad (2)$$

式中: ω 为高维空间权向量; b 为偏置常数。则最优问题为

$$\begin{aligned} \min R &= \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^m \xi_i^2 \\ y_i &= \omega^T \varphi(x) + b + \xi_i \\ (i &= 1, 2, \dots, m) \end{aligned} \quad (3)$$

式中: ξ_i 为松弛因子。

因此,可以定义如式(4)所示的 Lagrange 函数求解上述优化问题,即

$$L(\omega, b, \xi, \alpha, \gamma) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} \gamma \sum_{i=1}^m \xi_i^2 - \sum_{i=1}^m \alpha_i [\omega^T \varphi(x_i) + b + \xi_i - y_i] \quad (4)$$

式中: $\alpha_i \in \mathbf{R}(i=1, 2, \dots, m)$ 为拉格朗日乘子。根据 Karush-Kuhn-Tucher(KKT) 优化条件得到等式(5)。

$$\begin{bmatrix} 0 & 1 & \dots & m \\ 1 & K(x_1 + x_1) + \frac{1}{\gamma} & \dots & K(x_1 + x_m) \\ \dots & \dots & \dots & \dots \\ m & K(x_m + x_1) & \dots & K(x_1 + x_m) + \frac{1}{\gamma} \end{bmatrix} \cdot \begin{bmatrix} b \\ \alpha_1 \\ \dots \\ \alpha_m \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \dots \\ y_m \end{bmatrix} \quad (6)$$

式中: $K(x_i, x_j)$ 为核函数。用最小二乘法求出 α 和 b , 即得到非线性预测输出模型。

$$y = \sum_{i=1}^m \alpha_i K(x, x_i) + b \quad (7)$$

2.2.2 SVM 模型的优化 对于 SVM 参数选取的盲目性,采用 PSO 算法进行优化。数据进行初始化参数设定,生成随机粒子,创建一个二维空间,粒子群规模为 10。其中,第 i 个粒子的位置表示为向量 $x_i = (x_{i1}, x_{i2}), i=1, 2, \dots, 10$ 。其中, x_i 值中包含为 SVM 模型的核函数参数 σ 、惩罚因子 C ,将 x_i 带入到训练好的 SVM 模型中并计算出其均方误差,将均方误差作为适应度值,根据适应度值的大小评判出粒子的优劣。用向量 $V_i = (v_{i1}, v_{i2})$ 来代表粒子 i 的飞行速度,其搜索到的最优位置为 $p_i = (p_{i1}, p_{i2})$,而整个粒子群搜索到的最优位置为 $p_g = (p_{g1}, p_{g2})$,得到这两个最优值后,粒子就根据式(8)、式(9)进行速度和位置的更新。

$$v_{i+1} = \omega V_i + c_1 r_1 (p_i - x_i) + c_2 r_2 (p_g - x_i) \quad (8)$$

$$x_{i+1} = x_i + v_{i+1} \quad (9)$$

其中: $i=1, 2, \dots, 10$; ω 是惯性权重函数,随着迭代的增加而减小,用来控制前面速度对当前速度的影响;设置加速因子 $c_1 = 1.8$ 和 $c_2 = 1.7$; r_1 和 r_2 是 $[0, 1]$ 之间的随机数,进行 50 次迭代,粒子群迭代曲线如图 1 所示。

得到其最优参数为:均方误差 $mse=1.217$,核函数参数 $\sigma=10$,惩罚系数为 $C=6.6904$ 。带入 SVM 模型,建立 PSO-SVM 模型。

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \omega = \sum_{i=1}^m \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^m \alpha_i = 0 \\ \frac{\partial L}{\partial \xi} = 0 \rightarrow \alpha_i = \gamma \xi_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow \omega^T \varphi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (5)$$

将式(5)带入式(4),将 ω 和 ξ 消去,得到线性方程式(6)。




图 1 粒子群迭代曲线

Fig. 1 Particle swarm optimization algorithm iteration curve

2.3 BP 残差修正模型的建立

为进一步提高模型的精度,采用 BP 神经网络进行残差修正。用 PSO-SVM 模型对第 2 组数据进行预测,将预测值记录下来。以第 2 组数据中出厂水余氯量、出厂浊度和出厂 pH 值作为输入值 X_i ,以实测值与 PSO-SVM 预测值之间的偏差作为输出值 T_i ,组建训练样本 (X_i, T_i) ,建立 3 层前馈型 BP 神经网络,网络结构如图 2 所示。




图 2 BP 神经网络系统残差修正结构

Fig. 2 Residual correction structure of BP neural network system

对网络输入层、隐含层和输出层神经元之间的

连接权值 ω_{ij} 、 ω_{jk} 以及隐含层及输出层的阈值 a 、 b 进行初始化设置,然后,对模型进行训练,模型网络设置输入层到隐层传递函数为 tansig 函数,即

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (10)$$

根据输入的变量 X_i ,输入层和隐含层间连接权值 ω_{ij} 以及隐含层阈值 a ,计算隐含层输出值为 U_j 。

$$U_j = f\left(\sum_{i=1}^n \omega_{ij}x_i - a_j\right) \quad (11)$$

再采用 logsig 函数作为隐含层到输出层的传递函数,计算 BP 神经网络的预测输出 G_k 。

$$G_k = \sum_{j=1}^8 U_j \omega_{jk} - b_k \quad (12)$$

用期望输出 T 减去预测输出 G 得到误差集合 e_k ,然后用式(13)~式(16)对连接权值和阈值进行修正。

$$\omega_{ij} = \omega_{ij} + \eta H_j (1 - U_j) x(i) \sum_{k=1}^m \omega_{jk} e_k \quad (13)$$

$$\omega_{jk} = \omega_{jk} + \eta U_j e_k \quad (14)$$

$$a_j = a_j + \eta U_j (1 - U_j) \sum_{k=1}^m \omega_{jk} e_k \quad (15)$$

$$b_k = b_k + e_k \quad (16)$$

设置输出层传递函数为 logsig 函数,训练函数为 trainlm 函数,精度取 0.000 000 001,学习率为 0.1%,

训练次数 1 000 次,经过试验确定,隐含层数为 16 时,模型的均方误差最小,实验结果见图 3。




图 3 组合算法不同隐含层的均方误差

Fig. 3 The MSE of different hidden layers in combination algorithm

由此建立了 3-16-1 结构的 BP 神经网络残差模型,其中, $i=(1,2,3)$, $j=(1,2,\dots,16)$, $k=1$, 得出厂水的余氯浓度、pH 值及浊度和 PSO-SVM 模型预测误差的映射关系模型,即 BP 神经网络残差模型。

2.4 组合模型的建立与验证

2.4.1 组合模型的建立 将第 3 组数据带入上述 PSO-SVM 模型和 BP 神经网络残差模型内,验证组合模型的预测效果,由 PSO-SVM 模型得到管网末端余氯预测值 y ,由 BP 残差模型得到残差预测值 e ,则最终组合模型的最终预测结果 $y_e = y + e$ 。如图 4 所示。

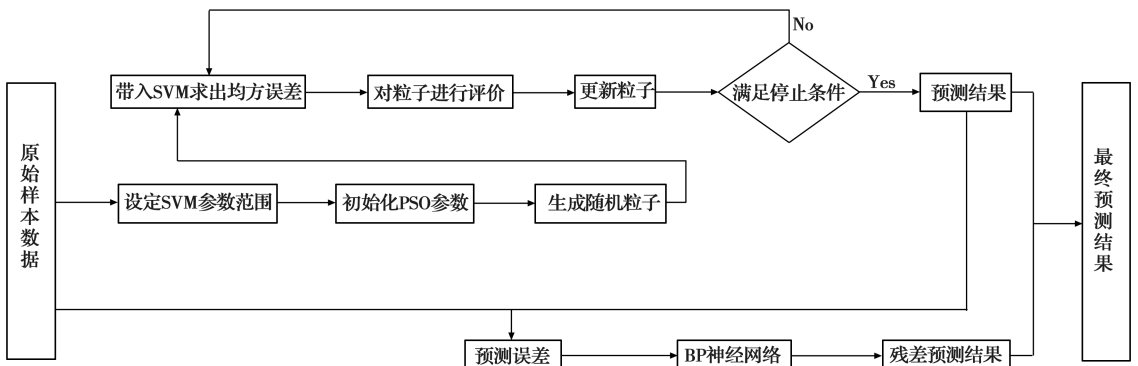


图 4 组合模型结构图

Fig. 4 Combined model flow chart

2.4.2 组合模型的结果验证 将第 3 组数据作为预测输入组合模型,并以相同的输入输出,分别输入 BP 神经网络和 PSO-SVM 模型中对余氯进行预测,以验证组合模型的预测效果,预测结果如图 5 所示。

由图 5 可知,单一的 BP 神经网络和 SVM 算法进行预测时,总体的预测误差较大,预测误差存在较大的波动,且对实际值拟合能力差。而组合模型的预测精度较单一模型而言有了显著的提高,具有更好的数据动态拟合能力和模型稳健性。为更直接分

析模型的准确性,从图 5 中提取 3 种模型的模拟误差,见表 1。

表 1 模型模拟精度对比

Table 1 Comparison of model simulation precision

模型类型	平均绝对误差	均方误差	R^2	平均相对误差/%	最大相对误差/%
组合模型	4.5×10^{-3}	4.2×10^{-5}	0.84	13.32	58.11
SVM 模型	1.1×10^{-2}	1.7×10^{-4}	0.67	29.13	75.35
BP 模型	9.2×10^{-3}	1.3×10^{-4}	0.72	29.62	107.80




图5 各算法预测结果比较

Fig. 5 Prediction results comparison for different arithmetic

从表1可知,单一的SVM算法与BP神经网络算法预测误差指标项相差不大,预测结果都不太理想,其均方误差分别为 1.7×10^{-4} 、 1.3×10^{-4} ,平均相对误差为29.13%、29.62%,相关指数 R^2 的值分别为0.67、0.72。而组合模型经过PSO优化和BP神经网络的修正后,能够大大地提升模型性能,降低预测误差,各项指标均优于单一模型,其均方误差为 4.2×10^{-5} ,平均相对误差为13.32%,相关指数 R^2 值达到0.84。综上,组合模型对信息的捕捉较全面,总体预测稳健性较好,可以大大地降低平均误差,提升模型的预测精度。

3 结论

通过PSO算法优化SVM模型参数,并使用BP神经网络对模型结果进行残差修正,建立了PSO-SVM+BP神经网络余氯预测模型,找到多个因素与管网末端余氯的关系,通过不同模型产生的误差进行模型性能的对比较分析。发现该模型可以实现对管网末端余氯量的预测,有效地简化了余氯在管网中衰减变化的复杂非线性关系,克服了SVM模型参数选择的盲目性,利用BP网络对结果进行优化,进一步提升了预测的精度和模型运行的稳健性。结果表明,该模型具有良好的预测性能,能够使供水企业更早地发现水质恶化的趋势,及时采取相关措施,在控制末端水水质的前提下,降低消毒副产物的产生,并为二次消毒点的选取提供参考。

参考文献:

- [1] 卫生部. 生活饮用水卫生标准[J]. 经济管理文摘, 2006(11):36-38.
Ministry of Health. Standards for drinking water quality [J]. Economic Management Digest, 2006(11): 36-38.
- [2] 周广宇, 莫罹, 赵新华, 等. 基于多组分水质模型的供水管网细菌风险研究[J]. 中国给水排水, 2016, 32(5): 64-69,73.
ZHOU G Y, MO L, ZHAO X H, et al. Assessment of bacteria risk in water distribution system based on multispecies water quality model [J]. China Water & Wastewater, 2016, 32(5): 64-69,73. (in Chinese)
- [3] 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, 48(Sup1): 471-475.
YANG H, LI M, YU G P. Water quality model of municipal network based on artificial neural network [J]. Water & Wastewater Engineering, 2012, 48(Sup1): 471-475. (in Chinese)
- [4] 戴舒, 郭姣. 南方某市供水管网水质模型的建立与校核[J]. 供水技术, 2017, 11(4):29-32.
DAI S, GUO J. Establishment and calibration of water quality model for water distribution system in a city of South China [J]. Water Technology, 2017, 11(4): 29-32.
- [5] 刘国红, 廖玉学, 黄广文, 等. 深圳市2016年生活饮用水水质影响因素[J]. 中国热带医学, 2018, 18(1): 72-75.
LIU G H, LIAO Y X, HUANG G W, et al. Factors influencing drinking water quality in Shenzhen, 2016 [J]. China Tropical Medicine, 2018, 18(1): 72-75. (in Chinese)
- [6] 谢昕, 郭鹏飞, 詹小丽, 等. 基于RBF神经网络的余氯浓度预测模型研究[J]. 传感器与微系统, 2012, 31(8): 64-65,68.
XIE X, GUO P F, ZHAN X L, et al. Research on prediction model of residual chlorine concentration based on RBF neural network [J]. Transducer and Microsystem Technologies, 2012, 31(8): 64-65,68. (in Chinese)
- [7] BOWDEN G J, NIXON J B, DANDY G C, et al. Forecasting chlorine residuals in a water distribution system using a general regression neural network [J]. Mathematical and Computer Modelling, 2006, 44(5/6): 469-484.

- [8] 何自立, 王云霏, 马孝义, 等. 基于改进 PSO-WNN 模型的管网余氯预测研究[J]. 中国农村水利水电, 2015(2): 86-88,92.
HE Z L, WANG Y F, MA X Y, et al. Residual chlorine prediction in water supply system based on improved PSO-WNN model [J]. China Rural Water and Hydropower, 2015(2): 86-88,92. (in Chinese)
- [9] 何自立, 郭占娟, 杨建国, 等. 基于 PSO-SVR 模型的供水系统余氯预测研究[J]. 长江科学院院报, 2015, 32(10): 6-10.
HE Z L, GUO Z J, YANG J G, et al. Residual chlorine prediction in water supply system based on support vector machine regression model optimized by PSO method[J]. Journal of Yangtze River Scientific Research Institute, 2015, 32(10): 6-10. (in Chinese)
- [10] 谢芳, 唐德善. 农业灌溉用水量的 LS-SVM 预测模型研究[J]. 安徽农业科学, 2010, 38(19): 10273-10275, 10288.
XIE F, TANG D S. Forecasting irrigation water requirement based on least squares support vector machine[J]. Journal of Anhui Agricultural Sciences, 2010, 38(19): 10273-10275,10288. (in Chinese)
- [11] ABHISEK U. Support vector machine[J]. Computer Science, 2002, 1(4):1-28.
- [12] SUN L F, ZHANG Y Y, SAQI R N. Research on the fouling prediction of heat exchanger based on support vector machine optimized by particle swarm optimization algorithm [C]//2009 International Conference on Mechatronics and Automation, Changchun, China, 2009: 2002-2007
- [13] EBERHART R C, SHI Y H. Comparison between genetic algorithms and particle swarm optimization [M]. Evolutionary Programming VII Springer Berlin Heidelberg, 1998:611-616.
- [14] LIU J, LIU Z, XIONG Y. Method of parameters optimization in SVM based on PSO[J]. Transactions on Computer Science & Technology, 2013, 2(1): 9-16.
- [15] 党安朋, 刘占峰, 朱延玲, 等. 基于 BP 与 Elman 神经网络的发动机缸壁间隙检测[J]. 山东交通学院学报, 2015, 23(1): 1-5.
DANG A P, LIU Z F, ZHU Y L, et al. The detection of engine cylinder wall clearance based on BP and elman neural network [J]. Journal of Shandong Jiaotong University, 2015, 23(1): 1-5. (in Chinese)
- [16] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013.
CHEN M. Principles and examples of MATLAB neural network [M]. Beijing: Tsinghua University press, 2013.
- [17] WANG J J, SHI P, JIANG P, et al. Application of BP neural network algorithm in traditional hydrological model for flood forecasting [J]. Water, 2017, 9(1): 48.
- [18] LI C, YU J, ZHANG T, et al. The effect of factors on chlorine decay and trihalomethane formation in a pilot-scale distribution system[J]. Fresenius Environmental Bulletin, 2014, 23(1):223-227.
- [19] POWELL J C, HALLAM N B, WEST J R, et al. Factors which control bulk chlorine decay rates [J]. Water Research, 2000, 34(1):117-126.
- [20] 钟丹, 袁一星, 马文成, 等. 供水管网内生物膜与余氯衰减交互作用[J]. 哈尔滨工业大学学报, 2017, 49(8): 49-54.
ZHONG D, YUAN Y X, MA W C, et al. Interaction effects between biofilm and chlorine decay in water distribution network [J]. Journal of Harbin Institute of Technology, 2017, 49(8): 49-54. (in Chinese)
- [21] 郝艳萍. 余氯衰减一级模型参数确定方法试验研究[D]. 哈尔滨: 哈尔滨工业大学, 2016.
HAO Y P. Study on method of the first order chlorine decay model parameters determination [D]. Harbin: Harbin Institute of Technology, 2016. (in Chinese)
- [22] 黄锐, 李翠梅, 罗贤达, 等. 影响供水管网中余氯与浊度的因素及相关性分析[J]. 给水排水, 2015, 51(5): 147-151.
HUANG R, LI C M, LUO X D, et al. Factors and correlation analysis of residual chlorine and turbidity in water supply pipe network [J]. Water & Wastewater Engineering, 2015, 51(5):147-151.
- [23] 田一梅, 吴迷芳, 王阳, 等. 基于 SVR 的城市供水管网余氯预测分析[J]. 重庆建筑大学学报, 2006, 28(2): 74-78.
TIAN Y M, WU M F, WANG Y, et al. Prediction and analyses of residual chlorine based on support vector regression in urban water distribution system[J]. Journal of Chongqing Jianzhu University, 2006, 28(2): 74-78. (in Chinese)