

DOI: 10.13476/j.cnki.nsbtdqk.2019.0126

赵二峰,尹文中,高嵩,等.基于 AdaBoost-SVM 的混凝土坝变形预测模型[J].南水北调与水利科技,2019,17(5):188-193.
ZHAO E F, YIN W Z, GAO S, et al. Research on dam deformation monitoring model based on Adaboost-SVM [J].
South-to-North Water Transfers and Water Science & Technology, 2019, 17(5): 188-193. (in Chinese)

基于 AdaBoost-SVM 的混凝土坝变形预测模型

赵二峰¹, 尹文中¹, 高嵩², 汪程¹, 陈悦¹, 杨群³

(1. 河海大学 水利水电学院, 南京 210098; 2. 扬州市勘测设计研究院有限公司, 江苏 扬州 225002;
3. 河北农业大学, 河北 保定 071001)

摘要:针对混凝土坝变形预测模型中环境量与效应量之间复杂的非线性问题,以及单支持向量机(SVM)模型预测精度不高的问题,提出一种 AdaBoost-SVM 的混凝土坝变形预测模型,该模型采用结构风险最小化的原则,并借鉴提升算法强化学习的思想,从而提高模型的学习性能,达到增强模型泛化能力和预测精度的目的。结合实例,经过 AdaBoost-SVM 预测模型对混凝土坝位移原型监测数据进行训练及预测,并将预测结果与单支持向量机模型的预测结果进行对比,结果显示:基于 AdaBoost-SVM 预测模型得到的均方差为 0.5565,平均误差绝对值为 0.40,预测精度比单支持向量机模型高出一个数量级;而且相较于单支持向量机预测模型,强化后的模型在预测时段表现出更好的稳定性。该模型综合了提升算法与支持向量机各自的优势,可作为混凝土坝变形预测的一种有效方法。

关键词: AdaBoost-SVM 预测模型; 变形; AdaBoost 算法; SVM; 预测精度

中图分类号: TV541 文献标志码: A 开放科学(资源服务)标识码(OSID):



Research on dam deformation monitoring model based on AdaBoost-SVM

ZHAO Erfeng¹, YIN Wenzhong¹, GAO Song², WANG Cheng¹, CHEN Yue¹, YANG Qun³

(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China;
2. Yangzhou Surveying and Design Institute of Water Resource Co, Ltd., Yangzhou 225002, China;
3. Hebei Agricultural University, Baoding 071001, China)

Abstract: Aiming of the complex non-linearity problem between environment and effect in concrete dam deformation prediction model and the low prediction accuracy of single support vector machine (SVM) model, an AdaBoost-SVM model for concrete dam deformation prediction was proposed. The model adopted the principle of minimizing structural risk and used the idea of learning algorithm for reference to improve the learning performance of the model for enhancing the generalization ability and prediction accuracy of the model. The prototype monitoring data of concrete dam displacement were trained and predicted by the AdaBoost-SVM prediction model, and the prediction results were compared with those of the single support vector machine model. The results showed that the mean square deviation of the prediction model based on AdaBoost-SVM was 0.5565, and the absolute average error was 0.40, while the prediction accuracy was one number higher than that of the single support vector machine model. In addition, compared with the single support vector machine prediction model, the enhanced model showed better stability in the prediction period. The model combined the advantages of lifting algorithm and support vector machine, and can be used as an effective method for deformation prediction of concrete dams.

收稿日期: 2019-04-04 修回日期: 2019-05-30 网络出版时间: 2019-06-11

网络出版地址: <http://kns.cnki.net/kcms/detail/13.1334.tv.20190606.1614.006.html>

基金项目: 国家重点研发计划(2016YFC0401601); 国家自然科学基金项目(51739003; 51779086; 51609074)

作者简介: 赵二峰(1986—), 男, 安徽亳州人, 副教授, 博士, 主要从事水工结构安全监控方面的研究。E-mail: m15830401812@163.com

通信作者: 尹文中(1992—), 男, 河北邯郸人, 助理工程师, 主要从事水工结构安全监控方面的研究。E-mail: 1049001419@qq.com

Key words: AdaBoost-SVM prediction model; deformation; AdaBoost algorithm; SVM; prediction accuracy

我国混凝土坝工程无论数量、高度、规模均居世界前列^[1],大坝在运行过程中,其健康状况不仅与工程周边的社会稳定和生态安全息息相关,而且也对大坝在发电、防洪、灌溉等方面的经济效益影响巨大^[2]。变形作为混凝土坝工作性态的直观反映^[3],如何通过对混凝土坝原型观测数据的分析,总结出混凝土坝在运行过程中的变形规律,实现对其变形趋势的准确模拟与预测^[4],对混凝土坝的安全运行来说意义重大。由于支持向量机(support vector machines, SVM)能够很好地处理小样本、非线性、高维数和局部极小点等实际问题^[5],并在很大程度上克服了“维数灾难”和“过学习”等缺陷^[6],使其在模式识别、回归估计、数据融合等领域应用广泛^[7-11];但是在实际应用中,由于影响混凝土坝变形的因素众多且复杂,在这种多因素的综合影响下,建立的单 SVM 模型往往受到支持向量的影响比较大,导致在预测精度上效果并不是很理想。基于 AdaBoost 算法在对训练样本反复学习的过程中,能够把超出预测误差范围外的样本加强学习,从而使其受到后一轮弱分类器的更大关注;然后加大预测误差率小的弱预测器的权值,增强其在表决过程中的作用,最后将多个弱学习预测器融合成为预测精度较高的强预测器的思路^[12],本文引入模式识别中分类器设计的重采样技术—Boosting 方法(增强法),提出一种 AdaBoost-SVM 的预测模型,尝试结合两种算法各自的特点,提高模型的学习性能和预测能力,克服单 SVM 模型预测精度不高的缺陷。

1 模型理论基础

1.1 支持向量机

支持向量机是由 Vapnik 等人提出的机器学习算法^[13],该算法建立在以结构风险最小化原则和 VC(Vapnik-Chervonenkis Dimension)维理论基础之上^[14]。SVM 的机理是在高维空间中找到最优分类面,即通过内积核函数所定义的非线性变换,将输入变量由低维空间转换到高维空间,从而把非线性问题转化为线性问题,并在高维空间中寻找输入变量和输出变量之间的线性关系。

在回归问题中,设样本个数为 n ,训练数据集为 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}, i = 1, 2, \dots, n$,通过非线性映射 $\phi(\cdot)$,将训练样本 x_i 从输入空间

R^m 映射到高维特征空间 $R^c: x_i \in R^m \rightarrow \phi(x_i) \in R^c$ (m 和 c 分别为输入空间和高维特征空间的维数),从而在维数 c 可能为无穷大的高维特征空间中构造出回归估计函数,即

$$y_i = \omega^T \phi(x_i) + b \quad (1)$$

式中: ω 为权向量; $\phi(x_i)$ 为高维特征空间中的第 i 个特征向量; b 为常数。

根据结构风险最小化原则,寻优问题可以转换为

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 + \frac{1}{2} C \sum_{i=1}^n \xi_i^2 \\ s. t. y_i = \omega^T \phi(x_i) + b + \xi_i \end{cases} \quad (2)$$

式中: C 为惩罚参数; ξ 为松弛变量。

为了解决上述优化问题,构建拉格朗日函数(Lagrange function),并引入拉格朗日乘子 α ,即

$$L(\omega, b, \xi, \alpha) = \frac{1}{2} \|\omega\|^2 + \frac{1}{2} C \sum_{i=1}^n \xi_i^2 - \sum_{i=1}^n \alpha_i [\omega^T \phi(x_i) + b + \xi_i - y_i] \quad (3)$$

Lagrange 函数的鞍点决定了约束最优化问题的解^[15],并且在鞍点处最优化问题的解满足对 ω 和 b 的偏导为 0,将该二次型规划问题转化为相应的对偶问题,即

$$\frac{\partial L}{\partial \omega} = 0; \frac{\partial L}{\partial b} = 0; \frac{\partial L}{\partial \xi} = 0; \frac{\partial L}{\partial \alpha} = 0 \quad (4)$$

得到如式(5)所示的约束条件:

$$\begin{cases} \omega = \sum_{i=1}^n \alpha_i \phi(x_i); \sum_{i=1}^n \alpha_i = 0; \alpha_i = C \xi_i; \\ y_i - \omega^T \phi(x_i) - b - \xi_i = 0 \end{cases} \quad (5)$$

消去 ω 和 ξ ,并引入一个满足 Mercer 条件的径向基核函数 $K(x_i, x_j)$ (其中 $i = 1, 2, \dots, n; j = 1, 2, \dots, n$),这样在高维空间中并不需要知道该变换的形式,只需要通过内积运算即可,可得线性方程组^[16]为

$$\begin{bmatrix} 0 & e^T \\ e & Q + \frac{I}{C} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中: $e = [1, 1, \dots, 1]^T$; Q 为 $n \times n$ 维矩阵: $Q = K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$; I 单位矩阵; $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]^T$; $y = [y_1, y_2, \dots, y_n]^T$ 。

可得预测模型为

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

1.2 AdaBoost 算法

AdaBoost 算法是由 Schapire 和 Freund 在 1995 年提出的一种提升算法,该算法的核心思想^[17]

是将一个训练集通过学习算法反复训练得到不同的基预测模型,然后把这些弱预测模型通过加权投票集合起来,构成一个更强的最终预测模型。不过在训练之前,首先应该确定一个误差界限 δ ,当输出变量与实际值的差值小于误差界限时,则表示预测正确,在下一轮训练过程中该样本权值降低;当输出变量与实际值的差值大于误差界限时,则表示预测错误,在下一轮训练过程中该样本权值增加。每一轮提升过后,对于误差率较小的预测模型,则增大其权重,使其在表决过程中增强影响;对于误差率较大的预测模型,则减小其权重,使其在表决过程中降低影响。

AdaBoost 算法的具体步骤^[18]如下。

(1)选取 N 组训练数据,初始化训练数据的权值分布为

$$D_1 = (w_{11}, \dots, w_{1i}, \dots, w_{1N}) \quad (8)$$

式中: D_1 表示训练数据初始权值集; w_{1i} 表示第 i 个数据的权值, $i=1,2,\dots,N$ 。

(2)设提升次数为 M ,计算第 $m(m=1,2,\dots,M)$ 个预测模型 $G_m(x)$ 训练数据集上的误差率

$$e_m = \sum_{i=1}^N w_{mi} \quad (9)$$

式中: w_{mi} 为提升 m 次后第 i 个数据的权值

$$w_{mi} = \begin{cases} w_{mi} & |G_m(x_i) - y_i| > \delta \\ 0 & |G_m(x_i) - y_i| < \delta \end{cases}$$

(3)计算预测模型 $G_m(x)$ 的权值

$$\alpha_m = \frac{1}{2} \log \frac{1 - e_m}{e_m} \quad (10)$$

(4)更新训练数据集的权值分布

$$D_{m+1} = (w_{m+1,1}, \dots, w_{m+1,i}, \dots, w_{m+1,N}) \quad (11)$$

$$w_{m+1,i} = \frac{w_{mi}}{Z_m} \begin{cases} e^{-\alpha_m} & |G_m(x_i) - y_i| < \delta \\ e^{\alpha_m} & |G_m(x_i) - y_i| > \delta \end{cases} \quad (12)$$

式中: D_{m+1} 表示提升 m 次后训练数据权值集; $w_{m+1,i}$ 表示提升 m 次后第 i 个数据的权值; Z_m 是规范化因子, $Z_m = \sum_{i=1}^N w_{mi} \begin{cases} e^{-\alpha_m} & |G_m(x_i) - y_i| < \delta \\ e^{\alpha_m} & |G_m(x_i) - y_i| > \delta \end{cases}$ 。

(5)经过 M 次迭代后,最终得到强预测模型 $f(x)$ 的表达式为

$$f(x) = \sum_{m=1}^M \frac{\alpha_m}{\sum_{m=1}^M \alpha_m} G_m(x) \quad (13)$$

2 AdaBoost-SVM 预测模型

AdaBoost-SVM 的建模流程如下:(1)将训练集数据和测试集数据进行预处理,并导入到 Matlab 程序中;(2)运用粒子群算法寻找最优的核参数和惩罚参数;(3)得到 SVM 弱预测模型,并计算其在训练

数据上的预测误差率;(4)计算弱预测模型的系数,并更新训练数据的权重;(5)构建弱预测模型的线性组合,得到最终强预测模型;(6)使用强预测模型对测试集数据进行预测,将还原后的预测值与实际值进行对比。AdaBoost-SVM 建模流程见图 1。

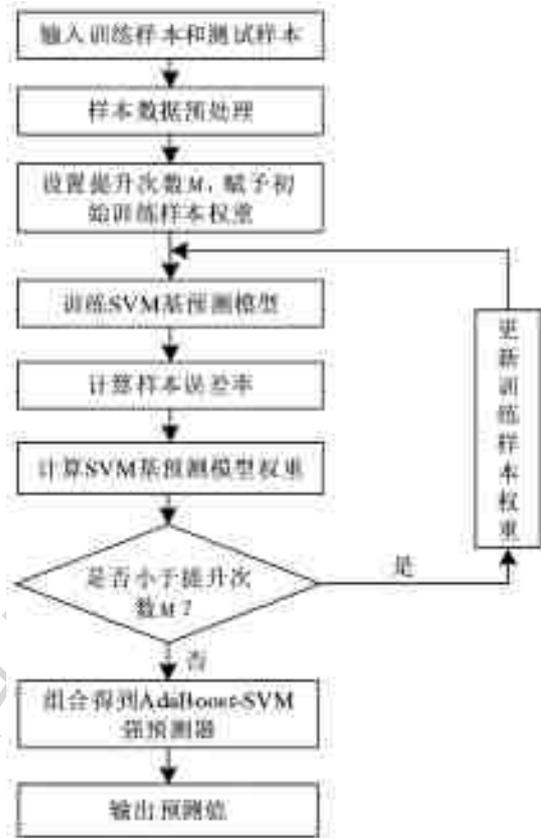


图 1 AdaBoost-SVM 建模流程
Fig. 1 AdaBoost-SVM modeling flow chart

3 实例分析

某混凝土重力坝为二级永久建筑物,坝顶高程 280 m,最大坝高 78 m,坝顶全长 253 m,共分 13 个坝段,从左往右编号为 2 号至 14 号。引张线布设在坝顶 280.0 m 高程处,自坝左到坝右依次布置 EX1 至 EX12 共 12 个测点,工作基点分别设在左右山坡。引张线起测日期为 2002 年 1 月,选取测点 EX7 在 2007 年 2 月 19 日至 2014 年 2 月 10 日期间共 328 组实测数据,其中将 2012 年 8 月 13 日—2014 年 2 月 10 日的 66 组观测值用于预测。

由于混凝土大坝发生水平位移的原因主要是水位、温度和时效,故选取 9 个影响因子:包括水位因子 3 个,分别为 $H - H_0$ 、 $(H - H_0)^2$ 、 $(H - H_0)^3$;温度因子 4 个,分别为 $\sin \frac{2\pi t}{365} - \sin \frac{2\pi t_0}{365}$ 、 $\cos \frac{2\pi t}{365} - \cos \frac{2\pi t_0}{365}$ 、 $\sin \frac{4\pi t}{365} - \sin \frac{4\pi t_0}{365}$ 、 $\cos \frac{4\pi t}{365} - \cos \frac{4\pi t_0}{365}$;时效因子 2 个,分别为 $\theta - \theta_0$ 、 $\ln \theta - \ln \theta_0$ 。其中, H 和 H_0 分

别为监测日和始测日当天所应对的上游水头; t 为从始测日开始到监测日当天的累计天数, t_0 为从始测日开始到建模资料系列第一个监测日的累计天数; θ 为监测日值始测日的累计天数除以 100, θ_0 为始测日到建模资料系列第一个监测日的累计天数 t_0 除以 100^[19]。

利用训练好的 AdaBoost-SVM 模型和 SVM 模型对该混凝土坝测点 EX7 进行预测,两种模型的拟合及预测情况分别见图 2、3,两种模型的误差绝对值对比情况见图 4;两种模型的均方差及预测结果对比情况分别见表 1、2。

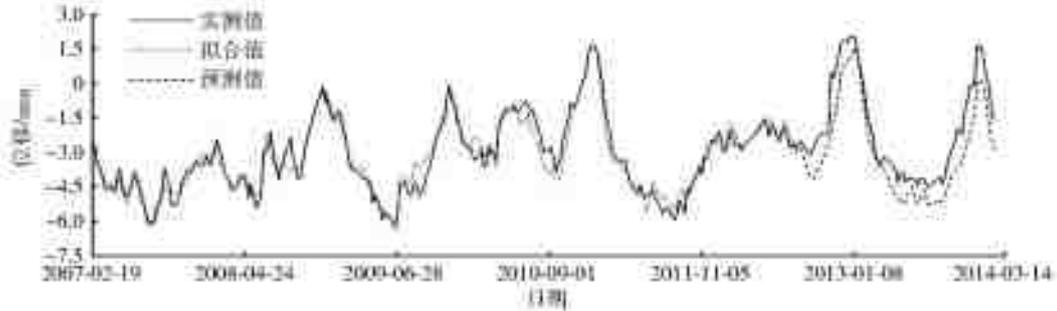


图 2 SVM 模型拟合及预测结果
Fig. 2 SVM Model's fitting and prediction results

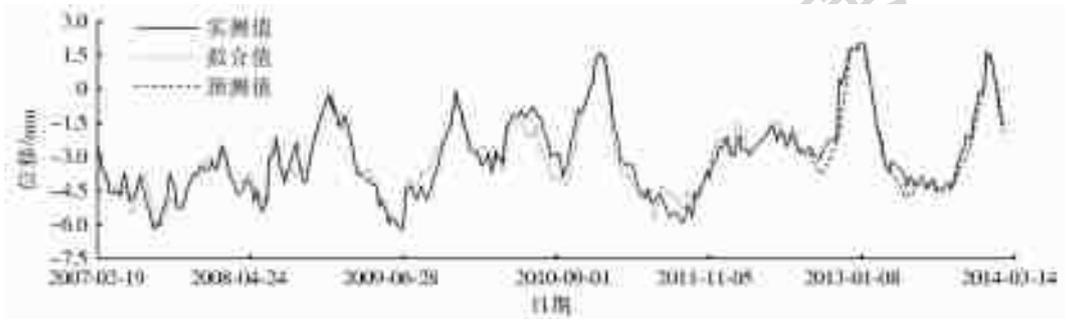


图 3 AdaBoost-SVM 模型拟合及预测结果
Fig. 3 AdaBoost-SVM model's fitting and predicting results

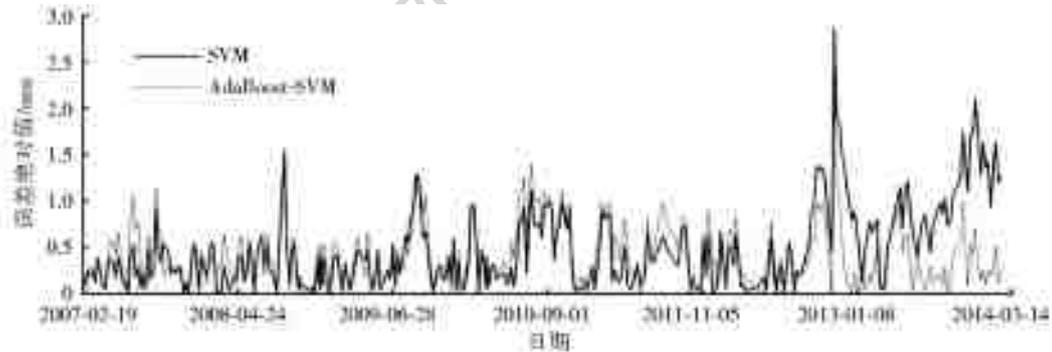


图 4 SVM 模型与 AdaBoost-SVM 模型的误差绝对值
Fig. 4 Absolute error value of SVM Model and AdaBoost-SVM Model

表 1 SVM 模型与 AdaBoost-SVM 模型的均方差

Tab. 1 Mean variance of SVM Model and AdaBoost-SVM Model

时段	AdaBoost-SVM 模型	SVM 模型
拟合时段	0.522 9	0.436 4
预测时段	0.556 5	1.160 7

选用均方差定量评估模型的拟合和预测精度,其表达式为

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

式中: σ 为位移均方差; n 为样本的个数; y_i 为实测

值; \hat{y}_i 为拟合值。

通过对图 2 至图 4 和表 1、2 的分析,可以看出如下结果。

(1)在拟合时段,AdaBoost-SVM 模型和 SVM 模型的拟合效果较好,两者拟合精度差别不大;AdaBoost-SVM 模型的均方差为 0.522 9, SVM 模型的均方差为 0.436 4。

(2)在预测时段,AdaBoost-SVM 模型能够较好的预测位移的实际变化情况,而 SVM 模型的预测效果较差,尤其在位移极值点附近,AdaBoost-SVM

表 2 SVM 模型与 AdaBoost-SVM 模型预测结果比较

Tab. 2 Prediction results comparison between SVM model and AdaBoost-SVM model

单位:mm

序号	实测值	SVM 模型 预测值	SVM 模型误 差绝对值	SVM 模型平均 误差绝对值	AdaBoost-SVM 模型预测值	AdaBoost-SVM 模型 误差绝对值	AdaBoost-SVM 模型 平均误差绝对值
263	-2.52	-2.83	0.31		-2.83	0.31	
264	-2.73	-3.16	0.43		-3.05	0.32	
265	-2.93	-3.49	0.56		-3.26	0.33	
266	-3.01	-3.91	0.90		-3.58	0.57	
⋮	⋮	⋮	⋮	1.04	⋮	⋮	0.40
325	0.26	-1.13	1.39		-0.01	0.27	
326	-0.36	-1.99	1.63		-0.88	0.52	
327	-1.33	-2.52	1.19		-1.44	0.11	
328	-1.62	-2.89	1.27		-1.88	0.26	

模型的预测精度明显高于 SVM 模型的预测精度; AdaBoost-SVM 模型的均方差为 0.556 5, SVM 模型的均方差为 1.160 7, 说明经过强化学习后的 SVM 模型, 其学习能力较强, 预测效果较好。

(3) 由表 2 可以看出, 在预测时段 AdaBoost-SVM 模型的预测值更加接近实测值, 其误差绝对值相对较小, 且随着时间的增长, 预测值仍然能够保持较高的精度, 说明其稳定性更好; SVM 模型的平均误差绝对值为 1.04, AdaBoost-SVM 模型的平均误差绝对值为 0.40, 说明 AdaBoost-SVM 模型的整体预测效果要优于 SVM 模型。

4 结 论

(1) AdaBoost-SVM 模型具有良好的非线性预测能力, 可应用在混凝土坝安全监控中。

(2) AdaBoost-SVM 模型相较于单 SVM 模型预测精度明显提高, 且与拟合时段相比, 误差波动较小, 稳定性更高。

(3) AdaBoost-SVM 预测模型在运算过程中耗时更长。因此, 如何减少提升次数, 缩短运算时间, 值得进一步思考和研究。

参考文献(References):

- [1] 顾冲时, 苏怀智. 混凝土坝工程长效服役与风险评定研究述评[J]. 水利水电科技进展, 2015, 35(5): 1-12. (GU C S, SU H Z. Current status and prospects of long-term service and risk assessment of concrete dams [J]. Advances in Science and Technology of Water Resources, 2015, 35(5): 1-12. (in Chinese)) DOI: 10.3880/j. issn. 10067647. 2015. 05. 001.
- [2] HUANG H, CHEN B, LIU C, et al. Safety monitoring of a super-high dam using optimal kernel partial least squares [J]. Mathematical Problems in Engineering,

2015(12):1-13. DOI:10.1155/2015/571594.

- [3] 顾冲时, 苏怀智, 王少伟. 高混凝土坝长期变形特性计算模型及监控方法研究进展[J]. 水力发电学报, 2016, 35(5):1-14. (GU C S, SU H Z, WANG S W. Advances in calculation models and monitoring methods for long-term deformation behavior of concrete dams [J]. Journal of Hydroelectric Engineering, 2016, 35(5): 1-14. (in Chinese)) DOI: 10.11660/slfdxb. 20160501.
- [4] 苏怀智, 温志萍, 吴中如. 基于 SVM 理论的大坝安全预警模型研究[J]. 应用基础与工程科学学报, 2009, 17(1):40-48. (SU H Z, WEN Z P, WU Z R. Research on dam safety early warning model based on SVM theory [J]. Journal of Basic Science and Engineering, 2009, 17(1):40-48. (in Chinese)) DOI: 10.16058/j. issn. 1005-0930. 2009. 01. 013.
- [5] 张向君, 张晔. 基于支持向量机的交互检验储层预测[J]. 石油物探, 2018, 57(4): 597-600. (ZHANG X J, ZHANG Y. Reservoir prediction through cross-validation based on support vector machine [J]. Geophysical Prospecting for Petroleum, 2018, 57(4): 597-600. (in Chinese)) DOI: 10.3969/j. issn. 1000-1441. 2018. 04. 014.
- [6] 田萌. 高斯核参数选择与正交多项式核构造[D]. 太原: 山西大学, 2017. (TIAN M. Parameter selection for the gaussian kernel and construction of orthogonal polynomial kernels [D]. Taiyuan: Shanxi University, 2017. (in Chinese))
- [7] 刘玉敏, 赵哲耘. 基于特征选择与 SVM 的质量异常模式识别[J]. 统计与决策, 2018, 34(10): 47-51. (LIU Y M, ZHAO Z Y. Quality anomaly pattern recognition based on feature selection and SVM [J]. Statistics & Decision, 2018, 34(10): 47-51. (in Chinese)) DOI: 10.13546/j. cnki. tjyc. 2018. 10. 010.
- [8] LEE C, KWON D. A similarity based prognostics approach for real time health management of electronics using impedance analysis and SVM regression [J]. Microelectronics Reliability, 2018, 83: 77-83. DOI: 10.1016/j. microrel. 2018. 02. 014.

- [9] QIAO RU LI,ZHAO R,CHEN L. Short-term traffic flow forecasting model based on SVM and adaptive spatio-temporal data fusion[J]. Journal of Beijing University of Technology, 2015. DOI:10.11936/bjtxb2014050068.
- [10] 葛赛,赵涛,吴思,等. 基于主成分分析-支持向量机的人工加糙渠道糙率系数预测模型[J]. 南水北调与水利科技, 2018, 16(3): 169-174. (GE S, ZHAO T, WU S, et al. Prediction model of roughness coefficient of artificially roughened channels based on principal component analysis-support vector machine [J]. South-to-North Water Transfers and Water Science & Technology, 2018, 16(3): 169-174. (in Chinese)) DOI:10.13476/j.cnki.nsbdkq.2018.0084.
- [11] 李波,刘明军,马奕仁,等. 基于平均曲率模态和最小二乘支持向量机的混凝土拱坝损伤识别方法研究[J]. 长江科学院院报, 2013, 30(11): 113-118. (LI B, LIU M J, MA Y R, et al. Damage identification of concrete arch dam using mean curvature mode and least squares support vector machine[J]. Journal of Yangtze River Scientific Research Institute, 2013, 30(11): 113-118. (in Chinese)) DOI: 10.3969/j.issn.1001-5485.2013.11.023.
- [12] 贺先辉. 基于特征学习的目标检测与跟踪技术研究[D]. 成都:中国科学院大学(中国科学院光电技术研究所), 2017. (HE X H. Study on the object detection and tracking based on feature learning[D]. Chengdu: The Institute of Optics and Electronics (Chinese Academy of Science), 2017. (in Chinese))
- [13] 楼雄伟. 支持向量机的核方法研究及其在森林火灾视频识别中的应用[D]. 杭州:浙江工业大学, 2014. (LOU X W. Research on kernel method for support vector machine and its application in forest fire video recognition[D]. Hangzhou: Zhejiang University of Technology, 2014. (in Chinese))
- [14] 董宝玉. 支持向量技术及其应用研究[D]. 大连:大连海事大学, 2016. (DONG B Y. Research on support vector techniques and their applications[D]. Dalian: Dalian Maritime University, 2016. (in Chinese))
- [15] 黄正海,苗新河. 最优化计算方法[M]. 北京:科学出版社, 2015: 224. (HUANG Z H, MIAO X H. Optimal calculation method[M]. Beijing: Science Press, 2015: 224. (in Chinese))
- [16] 肖浩波,谷艳昌. 混凝土坝安全监控最小二乘支持向量机模型[J]. 长江科学院院报, 2013, 30(5): 34-37. (XIAO H B, GU Y C. Monitoring model for concrete dam safety using least square support vector machine [J]. Journal of Yangtze River Scientific Research Institute, 2013, 30(5): 34-37. (in Chinese)) DOI: 10.3969/j.issn.1001-5485.2013.05.008.
- [17] DAHL G E, YU D, DENG L, et al. Large vocabulary continuous speech recognition with context-dependent DBN-HMMS [C]. 2011. DOI: 10.1109/ICASSP.2011.5947401.
- [18] 李航. 统计学习方法[M]. 北京:清华大学出版社, 2012: 14, 235. (LI H. Statistical Learning Method [M]. Beijing: Tsinghua University Press, 2012: 14, 235. (in Chinese))
- [19] 吴中如. 水工建筑物安全监控理论及其应用[M]. 北京:高等教育出版社, 2003: 405. (WU Z R. Safety monitoring theory and its application of hydraulic structures [M]. Beijing: Higher Education Press, 2003: 405. (in Chinese))

(上接第 179 页)

- [21] 丁开宁,郝爱兵,王孟科. 石家庄市地下水污染特征及机理[J]. 水文地质工程地质, 1996(6): 29-32. (DING K N, HAO A B, WANG M K. (The pollution mechanism of groundwater in Shijiazhuang [J]. Hydrogeology & Engineering Geology, 1996(6): 29-32. (in Chinese))
- [22] 程东会. 北京城近郊区地下水硝酸盐氮和总硬度水文地球化学过程及数值模拟[D]. 北京:中国地质大学(北京), 2007. (CHEN D H. The hydrogeochemical process and the numerical simulation of total hardness and nitrogen in groundwater of Beijing urban[D]. Beijing: China University of Geosciences (Beijing), 2007. (in Chinese))
- [23] 李纯,武强,王欣宝. 人类活动影响下石家庄市浅层地下水环境的演化[J]. 环境科学与技术, 2007, 30(8). (LI C, WU Q, WANG X B. Environmental evolution of shallow groundwater resulting from intensive human activities in Shijiazhuang City[J]. (in Chinese) DOI: 10.3969/j.issn.1003-6504.2007.08.016.
- [24] 张千千,王慧玮,翟天伦,等. 滹沱河冲洪积扇地下水硝酸盐的污染特征及污染源解析[J]. 水文地质工程地质, 2017(6): 116-123. (ZHANG Q Q, WANG H W, ZHAI T L, et al. Characteristics and source apportionment of groundwater nitrate contamination in the Hutuo River alluvial-pluvial fan regions[J]. Hydrogeology & Engineering Geology, 2017(6): 116-123. (in Chinese)) DOI: 10.16030/j.cnki.issn.1000-3665.2017.06.17.
- [25] LIU C Q, LI S L, LANG Y C, et al. Using delta15N-and delta18O-values to identify nitrate sources in karst ground water, Guiyang, Southwest China [J]. Environmental Science & Technology, 2006, 40(22): 6928. DOI: 10.1021/es0610129.