

基于GS-SVR模型的空腔积水水深和长度预测

郭港归¹,李国栋¹,魏杰²,王立杰²

(1. 西安理工大学西北旱区生态水利国家重点实验室,陕西 西安 710048;
2. 中国电建集团中南勘测设计研究院有限公司,湖南 长沙 410014)

摘要:为描述掺气减蚀工程中的空腔积水水深、空腔长度与诸多影响因素的非线性关系,实现空腔积水水深和空腔长度的准确计算,在搜集162组试验数据的基础上,建立了支持向量机回归(GS-SVR)模型。通过网格搜索和交叉验证方法,研究了GS-SVR模型中超参数(C 和 γ)的相互关系和其对GS-SVR模型预测准确度的影响机制,分析了6种不同输入组合(共12组)的模型性能。结果表明:通过网格搜索可以找到模型性能最佳的区域,该区域中 C 和 γ 呈现相反的增长趋势;基于上述方法找到了最佳变量组合($i_1, i_2, Fr, \Delta/h$),并且实现了对掺气坎空腔长度和空腔积水水深的精准预测。

关键词:空腔积水水深;空腔长度;网格搜索;支持向量机;超参数

中图分类号:TV135.2 文献标志码:A 文章编号:1006-7647(2022)06-0105-06

Prediction of backwater depth and cavity length based on GS-SVR model//GUO Gangui¹, LI Guodong¹, WEI Jie², WANG Lijie² (1. State key Laboratory of Eco-hydraulics in Northwest Arid Region of China, Xi'an 710048, China; 2. POWERCHINA Zhongnan Engineering Corporation Limited, Changsha 410014, China)

Abstract: In order to describe the nonlinear relationship between the cavity backwater depth, cavity length and many influencing factors in aeration erosion reduction projects, and to achieve the accurate calculation of backwater and cavity length, a support vector machine regression model (GS-SVR) by means of machine learning was established based on the collection of 162 sets of model experimental data. Through the method of grid search and cross-validation, the relationship between the hyperparameters (C and γ) in the support vector machine model and its influence mechanism on the accuracy of the model's prediction were studied. On this basis, the model performance of six different input combinations (a total of twelve groups) was analyzed. The results show that the region with the best model performance can be found through grid search. In this region, C and γ show the opposite growth trend. Based on the above method, the optimal variable combination can be found ($i_1, i_2, Fr, \Delta/h$) and the accurate prediction of the cavity length and the backwater depth is realized.

Key words: cavity backwater depth; cavity length; grid search; support vector machine; hyperparameters

水流掺气^[1-2]是防止高水头泄水建筑物空化空蚀的主要措施。然而,小底坡下的掺气坎常出现空腔回水现象,导致空腔形态较差,严重时甚至被积水填满,导致掺气量不足,难以达到掺气减蚀的效果。空腔积水水深和空腔长度是衡量掺气设施效率的重要指标^[3],因此研究坎下水力特性与空腔积水水深、空腔长度的关系具有重要的工程价值。前人对空腔积水水深和空腔长度进行了较多的理论公式推导:杨永森等^[4]运用动量方程对控制水体进行受力分析,计算出空腔积水深度;徐一民等^[5-6]以微元法

为基础,建立空腔回水方程计算空腔积水水深和空腔长度,计算值与试验值趋势一致;Chanson^[7]利用抛射体公式计算射流空腔长度和回水长度,与实测值相比计算结果偏大;潘水波^[8]对抛射体公式引入3个修正系数,计算精度相对提升。

目前机器学习的方法已广泛应用于局部冲刷、水质预测和流量系数预测等水科学领域,人工神经网络(artificial neural network, ANN)和支持向量机(support vector machine, SVM)是其中重要的方法。由于ANN需要设置复杂的网络结构参数,导致模型

基金项目:国家自然科学基金(51579206)
作者简介:郭港归(1997—),男,硕士研究生,主要从事水力学及河流动力学研究。E-mail:979751537@qq.com
通信作者:李国栋(1967—),男,教授,博士,主要从事水力学及河流动力学研究。E-mail:gdli2008@xaut.edu.cn

收敛缓慢,甚至在小样本数据下容易造成过拟合^[9],降低预测准确度。SVM 以最小结构化风险原则代替传统经验风险方法^[10],在处理小样本数据中有着天然的优势,泛化能力强,有效防止过拟合,其拓扑结构主要由自身的超参数决定,通过对超参数(C 和 γ)进行优化使模型达到较高的预测精度。Zaji等^[11]用适凑法确定了 SVM 模型的超参数并对三角形侧堰的流量系数进行预测;Jain^[12]通过现场实测数据建立 SVM 模型模拟河道水位、流量和含沙量的关系;Kiyomars等^[13]采用粒子群算法(PSO)优化 SVM 模型实现对阶梯溢洪道流量系数和消能率的预测;赵庆志等^[14]通过网格搜索的方法对超参数进行寻优,得到了基于 LS-SVM 的短期降雨预测模型。

本文通过网格搜索和交叉验证的方法建立 SVM 回归(GS-SVR)模型,研究超参数 C 和 γ 之间的规律和其对模型性能的影响。基于 GS-SVR 模型,依据评估指标判别 6 种参数输入中的最优组合,实现了对空腔积水深度和空腔长度的准确预测,并采用敏感性分析寻找对该模型起关键作用的因素。

1 试验数据

本文基于沈春颖^[15]的试验数据集,建立 GS-SVR 模型。试验水槽全长 7.6 m,槽宽 10 cm,来流量的范围为 0~5.5 L/s,挑坎体形如图 1 所示。在不同的挑坎体形和来流条件下进行模型试验,分别测量水深 h 、挑坎坡度 i_1 、挑坎高度 Δ 、空腔积水水深 h_1 、空腔长度 L 、水舌冲击角 θ 和底坡坡度 i_2 。试验数据总量 162 组,范围见表 1。




图 1 掺气坎布置方式

采用皮尔逊相关系数 r 反映各变量之间的相关性,皮尔逊相关系数如图 2 所示,图中 v 为坎顶流速。试验输出变量包括 h_1 和 L ,其余除 θ 以外均为输入变量。当 2 个变量之间的皮尔逊相关系数 $|r| > 0.3$,则认为两变量之间相关性较强,输入变量应避免两两之间有较强的相关性,确保变量的相对独立

性。由图 2 可知,输入变量之间的相关系数的绝对值多数小于 0.3,表明各输入变量独立性较好。输出变量 h_1 与 Δ 、 θ 和 i_2 的相关性较强,相关系数分别为 0.73、0.5、-0.43,当 Δ 和 θ 增大时,均导致 h_1 增加,而随着 i_2 增大, h_1 减少;输出变量 L 受到 Δ 和 v 的影响较大,相关系数分别为 0.61 和 0.57,说明 v 和 Δ 增加时, L 随之增加。




图 2 变量相关性分布

2 GS-SVR 模型的建立

先利用量纲分析法确定需要的输入变量,在此基础上选择不同的输入组合,并对其进行归一化处理。采用网格搜索和交叉验证的方法优化不同训练样本比例和输入组合的 SVM 模型,建立最佳输入组合下的 GS-SVR 模型,并分析模型超参数 C 和 γ 的分布规律。

2.1 量纲分析与变量组合

采用表 1 中的物理模型试验数据建立 SVM 模型,预测小底坡低弗劳德数泄洪洞的 h_1 、 L 。 h_1 和 L 是衡量掺气设施是否符合要求的重要指标。根据文献[16]可知 h_1 和 L 均受到以下因素的影响:

$$Y=f(i_1,i_2,h,v,\Delta,\Delta p) \tag{1}$$

式中: Y 为 h_1 或 L ; Δp 为空腔内外压力差。掺气设施通气充分时, Δp 对空腔长度和空腔积水水深的影响可以忽略不计。基于量纲分析方法^[17],可由式(1)得到:

$$\frac{Y}{h}=f(i_1,i_2,Fr,\frac{\Delta}{h}) \tag{2}$$

由于 Δ 与 h 具有相同量纲,因此等效后得到另一种形式:

$$\frac{Y}{\Delta}=f(i_1,i_2,Fr,\frac{\Delta}{h}) \tag{3}$$

表 1 试验数据范围

i_2	h/cm	Fr	Δ/cm	i_1	L/cm	θ	h_1/cm	样本量
0.07	1.50~3.40	2.46~3.27	1.0,2.0,3.0	0.10,0.143,0.20	4.9~20.2	6~20	0.40~1.85	54
0.087	1.35~3.30	2.55~3.62	1.0,2.0,3.0	0.10,0.143,0.20	5.0~22.0	6~20	0.60~1.70	54
0.096	1.25~3.25	2.62~3.90	1.0,2.0,3.0	0.10,0.143,0.20	5.2~26.5	5.5~19	0.40~1.30	54

变量组合见表 2 和表 3,WD1 ~ WD4 与 CL1 ~ CL4 以式 (2) 为基础的输入组合,输入变量依次降低,探究变量数目对模型的影响;WD5 ~ WD6 与 CL5 ~ CL6 以式 (3) 为基础的的输入组合,对比不同量化方式对模型性能的影响。

表 2 空腔积水水深模型的变量组合

预测模型	变量组合	预测模型	变量组合
WD1	$\frac{h_1}{h}=f(i_1,i_2,Fr,\frac{\Delta}{h})$	WD4	$\frac{h_1}{h}=f(\frac{\Delta}{h})$
WD2	$\frac{h_1}{h}=f(i_2,Fr,\frac{\Delta}{h})$	WD5	$\frac{h_1}{\Delta}=f(i_1,i_2,Fr,\frac{\Delta}{h})$
WD3	$\frac{h_1}{h}=f(Fr,\frac{\Delta}{h})$	WD6	$\frac{h_1}{\Delta}=f(i_2,Fr,\frac{\Delta}{h})$

表 3 空腔长度模型的变量组合

预测模型	变量组合	预测模型	变量组合
CL1	$\frac{L}{h}=f(i_1,i_2,Fr,\frac{\Delta}{h})$	CL4	$\frac{L}{h}=f(\frac{\Delta}{h})$
CL2	$\frac{L}{h}=f(i_2,Fr,\frac{\Delta}{h})$	CL5	$\frac{L}{\Delta}=f(i_1,i_2,Fr,\frac{\Delta}{h})$
CL3	$\frac{L}{h}=f(Fr,\frac{\Delta}{h})$	CL6	$\frac{L}{\Delta}=f(i_2,Fr,\frac{\Delta}{h})$

2.2 数据预处理

2.2.1 归一化处理

原始数据中,各变量之间的数值差异较大,影响模型的预测性能,因此对数据进行预处理是必要的。在无量纲化后,采用式 (4) 进行归一化,统一变量范围到 0 ~ 1 之间。

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{4}$$

式中: $x_{\min}$ 为样本数据的最小值; $x_{\max}$ 为样本数据的最大值; x^* 为归一化后的值。

2.2.2 训练集、测试集和交叉验证

许多研究者只将数据集分为训练集和测试集,模型从训练集中学习,在测试集中调整 SVR 模型超参数。而实际中很多时候缺少未来的数据,并且由于测试集用于模型调参,导致测试数据的信息提前泄漏到模型中,造成模型预测结果精度偏高、不能反映模型的泛化性能,容易产生过拟合^[18]。为了解决上述问题,需要提取一部分数据作为验证集,模型在训练集上学习,在验证集上调参,测试集用于最终评估。然而,数据集分为 3 组将大大减少可用于模型学习的样本数量,造成模型训练不充分,导致计算结果存在随机性,而 k 折交叉验证 (k -CV) 的方法能有效解决样本容量小的问题。 k -CV 将原训练集拆分为 k 个较小的集合,对于每一个小集合都遵循以下原则:①使用 $k-1$ 折数据作为模型的训练数据;②模型对剩下 1 折数据进行验证;③ k -CV 的模型评估指标是 k 次循环中的平均值(该指标可用于模型泛

化水平的度量)。交叉验证的方法不会浪费数据,非常适合数据样本总量较少的情况。本试验将采用五折交叉验证的方法,具体步骤如图 3 所示。




图 3 五折交叉验证示意图

2.2.3 训练样本抽取比例

训练样本数量占总样本数量的比重会影响 SVR 模型的性能。本试验选取训练样本抽取比例分别为 50%、60%、70% 和 80%,采用网格搜索和交叉验证的方法预测空腔积水水深 h_1 和空腔长度 L 。模型指标选取相关系数 R^2 ,不同抽取比例下的分布如图 4 所示。由图 4 可知,随着训练样本量增加,训练集、交叉验证集 (CV) 和测试集的模型指标 R^2 均增加。说明该模型性能随着训练数据的增加而提高。因此,本次试验选择训练集占总样本集的 80% 为基准比例。




图 4 SVR 模型指标分布

2.3 网格搜索法优化 GS-SVR 模型超参数

GS-SVR 模型具有良好的泛化性能,而其模型性能依赖于它的超参数^[19]。SVR 的超参数主要包括正则化系数 C 和核参数 γ 。 C 代表模型复杂度^[20-21], C 取值较大时,模型会尽可能拟合所有训练数据,可能造成模型过拟合。核参数 γ 是核函数的

内置参数,代表影响支持向量的强度^[20]。

网格搜索^[22]是最常见的寻优算法之一,其主要目的是让寻优超参数 C 和 γ 在一定坐标范围内、根据规定步长划分网格,并遍历所有的网格,对选定的网格节点的所有超参数组合 C 和 γ 利用 k 折交叉验证得到模型交叉验证评估指标 (R^2),最终取使模型交叉验证评估指标 R^2 最高的那组 C 、 γ 为最佳超参数组合。

图5为基于网格搜索下的 h_1 和 L 预测模型的超参数分布,其中 C 和 γ 均在 $2^{-8} \sim 2^8$ 之间,分别在各范围内取 100 个网格点 (总网格数 $100 \times 100 = 10\,000$),根据图上的等高线和颜色分布可以找到交叉验证评估指标 R^2 取值较大时的位置。试验结果表明,在所有的输出组合和训练抽取比例下,交叉验证评估指标均呈现相似的分布,因此仅展示 3 张图 (图5)。图5中 C 和 γ 对模型性能影响较大。中间黄色区域的 $R^2 > 0.7$,模型性能较好;左上和左下深蓝色区域 C 取值较小,造成模型欠拟合;图右上浅蓝色区域 γ 较大导致模型过拟合,模型性能不理想。深黄色区域中模型性能进一步提高 (交叉验证评估指标 $R^2 > 0.86$),沿着该区域能够找到交叉验证评估指标 R^2 取值最大的点,该点对应最优超参数组合。深黄色区域中,当 C 增至 $+\infty$ 时,则 γ 趋于 $-\infty$,说明超参数处于相反的增长趋势。 C 增大实现模型对样本充分训练,同时减少 γ 防止其过度训练,最终模型的预测结果处于最佳状态,因此 SVR 保持其良好泛化性能和高预测精度的机制是通过平衡 C 和 γ 的大小来实现的。

3 GS-SVR 模型计算结果与分析

3.1 模型计算结果

空腔回水和空腔长度是小底坡、低弗劳德数泄洪洞掺气设施设计中关注的指标,通过 GS-SVR 分

别对 6 种参数不同输入组合进行分析,模型评估指标选取 R^2 和均方根误差 RMSE。

表4和表5分别为 h_1 和 L 在训练集抽取比例为 80% 下的模型指标。与其他模型相比,WD1 和 CL1 为 2 种输出变量 (h_1, L) 下的最佳模型。WD1 的最佳性能在参数 C 、 γ 取值为 $2^{7.8}$ 、 $2^{-4.6}$ 时,测试集的 R^2 和 RMSE 分别为 0.849、0.082,对应的输入组合为 $\frac{h_1}{h} = f(i_1, i_2, Fr, \frac{\Delta}{h})$; CL1 的最佳性能在参数 C 、 γ 取值为 $2^{7.8}$ 、 $2^{-4.1}$ 时,测试集的 R^2 和 RMSE 分别为 0.956、0.061,对应的输入组合为 $\frac{L}{h} = f(i_1, i_2, Fr, \frac{\Delta}{h})$ 。说明对于合适的输入组合,SVM 能够实现对空腔积水水深和空腔长度的有效、精准预测。从 WD1 ~ WD4 和 CL1 ~ CL4 发现,随着输入变量数目减少,预测精度显著降低。此时,由表4和表5可

表4 空腔积水水深的模型指标

模型 编号	训练集		交叉验证集		测试集		C, γ 组合
	R^2	RMSE	R^2	RMSE	R^2	RMSE	
WD1	0.897	0.074	0.906	0.074	0.849	0.082	$2^{7.8}, 2^{-4.6}$
WD2	0.884	0.082	0.857	0.088	0.809	0.085	$2^{7.8}, 2^{-3.6}$
WD3	0.788	0.111	0.767	0.113	0.600	0.124	$2^{5.2}, 2^{-1.2}$
WD4	0.717	0.128	0.694	0.129	0.638	0.118	$2^{4.1}, 2^{-0.4}$
WD5	0.539	0.154	0.366	0.179	0.549	0.149	$2^{5.5}, 2^{-1.3}$
WD6	0.511	0.159	0.444	0.168	0.498	0.157	$2^{-1.4}, 2^{1.5}$

表5 空腔长度的模型指标

模型 编号	训练集		交叉验证集		测试集		C, γ 组合
	R^2	RMSE	R^2	RMSE	R^2	RMSE	
CL1	0.892	0.085	0.881	0.092	0.956	0.061	$2^{7.8}, 2^{-4.1}$
CL2	0.805	0.115	0.748	0.127	0.897	0.094	$2^{7.3}, 2^{-7.2}$
CL3	0.658	0.152	0.615	0.155	0.727	0.154	$2^{5.5}, 2^{-1.3}$
CL4	0.622	0.160	0.587	0.161	0.691	0.164	$2^{2.9}, 2^{-1.8}$
CL5	0.776	0.091	0.750	0.094	0.786	0.092	$2^{3.4}, 2^{-3.4}$
CL6	0.754	0.096	0.689	0.104	0.709	0.108	$2^{2.5}, 2^{-0.1}$




图5 网格搜索中 R^2 的分布情况

见,最佳参数 $C(\gamma)$ 随着变量数目降低呈现下降(增加)趋势。 C 反映模型复杂度,而变量数目较多时,样本复杂度较高,可通过增大 C 提高模型复杂度,更好地拟合训练样本;核参数 γ 影响支持向量强度,当 C 取值过大时及时降低 γ 来调整模型的复杂度,防止过拟合。因此样本的复杂度与模型复杂度相互匹配,模型的超参数相互制约,共同维持模型性能的稳定。

WD5 的输入组合为 $\frac{h_1}{\Delta}=f(i_1, i_2, Fr, \frac{\Delta}{h})$, 测试集的模型指标 R^2 为 0.549, RMSE 为 0.149, 与 WD1 ~ WD4 相比, WD5 的模型性能远远低于其他模型; CL5 的输入组合为 $\frac{L}{\Delta}=f(i_1, i_2, Fr, \frac{\Delta}{h})$, 相应的测试集模型指标 R^2 为 0.786, RMSE 为 0.092, 相比 CL1 和 CL2 仍有差距。因此,合适的量纲化方式将极大改善模型性能。

3.2 模型敏感性分析

WD1 和 CL1 变量组合下的 GS-SVR 模型性能最佳,此时 2 种输入变量组合均为 $(i_1, i_2, Fr, \frac{\Delta}{h})$, 在此基础上为了探究其中某一项因素对模型性能的影响,采用轮流移出变量来探究缺少该变量的模型性能。图 6 为敏感性分析试验结果,横坐标为测量值,纵坐标为预测值,当两者值越接近,直线斜率越接近 1,模型性能越好。由图 6 可知,影响空腔积水水深模型的主要因素是 $\frac{\Delta}{h}$, 缺少该因素的测试集 $R^2 =$

0.628;其次,底坡 i_2 也对模型性能有一定影响,缺少 i_2 后测试集 $R^2=0.776$;而缺少 Fr 和 i_1 的测试集 R^2 分别为 0.864 和 0.867。 $\frac{\Delta}{h}$ 也是影响空腔长度模型的关键因素,缺少该项后的测试集 R^2 为 0.796,而缺少 i_1 、 Fr 和 i_2 的测试集 R^2 分别为 0.832、0.945 和 0.925。

结合变量相关性分析发现,相关性分析与敏感性分析联系紧密,相关系数大的输入变量对模型影响大。因此,在建模之前可以通过相关性分析选择重要的输入变量。

4 结 论

a. 原数据中,各输入变量之间独立性较好;输出变量空腔积水水深和空腔长度均与输入变量存在相关性。根据不同抽取比例训练集的结果发现,小样本容量中,较大的训练集抽取比例能提高 GS-SVR 模型的性能。

b. 通过网格搜索和交叉验证的方法对模型超参数进行优化,发现该方法能找到最佳超参数组合、提高模型性能,并且 GS-SVR 模型计算结果的高准确度机制是通过超参数 C 和 γ 的相互制约来实现。

c. 6 种不同输入组合的计算结果表明,保持 GS-SVR 模型复杂度和样本复杂度一致并且采用合适的量纲化方式会极大改善模型性能,在此基础上寻找最佳变量组合,实现对空腔积水水深、空腔长度的精准预测。

d. 敏感性分析发现,空腔积水水深模型对坎高和坎下底坡较为敏感,空腔长度模型仅对坎高敏感。本文试验由于弗劳德数变幅较小,而 SVM 预测结果依赖于试验数据,故建模型的通用性有待考量,未来可收集更多掺气坎体型下的试验数据,扩大模型应用范围。

参考文献:

[1] 马旭东,戴光清,杨庆,等. 突扩突跌掺气射流对泄洪洞侧墙水力特性的影响[J]. 水力发电学报,2012,31(3): 142-147. (MA Xudong, DAI Guangqing, YANG Qing, et al. Effect of aerated jet on hydraulic characteristics of spillway tunnel side-wall with abrupt lateral expansion and bottom offset aerator[J]. Journal of Hydroelectric Engineering, 2012, 31(3): 142-147. (in Chinese))

[2] 张红梅,刘经强,于新雨,等. 突扩式跌坎消力池掺气特性试验[J]. 水利水电科技进展,2021,41(6): 82-87. (ZHANG Hongmei, LIU Jingqiang, YU Xinyu, et al. Experimental research on aeration characteristics of a




图 6 敏感性分析

- stilling pool with drop sill and sudden expansion [J]. Advances in Science and Technology of Water Resources, 2021, 41(6): 82-87. (in Chinese))
- [3] 王芳芳, 吴时强, 王威. 小底坡泄洪洞突扩跌掺气坎水力特性[J]. 水力发电学报, 2017, 36(7): 65-73. (WANG Fangfang, WU Shiqiang, WANG Wei. Hydraulic characteristics of sudden lateral enlargement and bottom drop aerators in spillway tunnels with mild slope [J]. Journal of Hydroelectric Engineering, 2017, 36(7): 65-73. (in Chinese))
- [4] 杨永森, 杨永全, 帅青红. 低 Fr 数流动跌坎掺气槽的水力及掺气特性[J]. 水利学报, 2000, 31(2): 27-31. (YANG Yongsen, YANG Yongquan, SHUAI Qinghong. The hydraulic and aeration characteristics of low Froude number flow over a step aerator [J]. Journal of Hydraulic Engineering, 2000, 31(2): 27-31. (in Chinese))
- [5] 徐一民, 王伟, 许唯临, 等. 掺气坎射流空腔积水计算[J]. 自然科学进展, 2008(5): 591-595. (XU Yimin, WANG Wei, XU Weilin, et al. Investigation on the cavity backwater of the jet flow from the chute aerators [J]. Progress in Natural Science, 2008(5): 591-595. (in Chinese))
- [6] 徐一民, 王伟, 许唯临, 等. 掺气坎(槽)射流空腔长度的计算[J]. 水利水电技术, 2004, 35(10): 7-9. (XU Yimin, WANG Wei, XU Weilin, et al. Calculation of the cavity length of jet flow from chute aerators [J]. Water Resources and Hydropower Engineering, 2004, 35(10): 7-9. (in Chinese))
- [7] CHANSON M H. Predicting the filling of ventilated cavities behind spillway aerators [J]. Journal of Hydraulic Research, 1995, 33(3): 361-372.
- [8] 潘水波. 通气挑坎射流的挟气能力[J]. 水利学报, 1980, 11(5): 13. (PAN Shuibao. The self-aeration of capacity of the water jet over the aeration ramp [J]. Journal of Hydraulic Engineering, 1980, 11(5): 13. (in Chinese))
- [9] 张哲铭, 李晓瑜, 姬建. 基于 LS-SVM 的 TBM 掘进参数预测模型[J]. 河海大学学报(自然科学版), 2021, 49(4): 373-379. (ZHANG Zheming, LI Xiaoyu, JI Jian, et al. TBM excavation parameter prediction model based on LS-SVM method [J]. Journal of Hohai University (Natural Sciences), 2021, 49(4): 373-379. (in Chinese))
- [10] 王瑞, 陈泽坤, 谔静. 基于 VMD 和 IBA-LSSVM 的短期风电功率预测[J]. 河海大学学报(自然科学版), 2021, 49(6): 575-582. (WANG Rui, CHEN Zekun, LU Jing. Short term prediction of wind power based on VMD and IBA-LSSVM [J]. Journal of Hohai University (Natural Sciences), 2021, 49(6): 575-582. (in Chinese))
- [11] ZAJI A H, BONAKDARI H. Optimum support vector regression for discharge coefficient of modified side weirs prediction [J]. INAE Letters, 2017, 2(1): 25-33.
- [12] JAIN S K. Modeling river stage-discharge-sediment rating relation using support vector regression [J]. Nordic Hydrology, 2012, 43(6): 851-861.
- [13] KIYOU MARS R, SAMIRA A. Particle swarm optimization-based LS-SVM for hydraulic performance of stepped spillway [J]. ISH Journal of Hydraulic Engineering, 2018, 26(3): 1-10.
- [14] 赵庆志, 刘洋, 姚顽强. 利用最小二乘支持向量机的短临降雨预测模型构建[J]. 大地测量与地球动力学, 2021, 41(2): 152-156. (ZHAO Qingzhi, LIU Yang, YAO Wanqiang. Establishment of short-term rainfall forecast model by least square support vector machine [J]. Journal of Geodesy and Geodynamics, 2021, 41(2): 152-156. (in Chinese))
- [15] 沈春颖. 小底坡低佛氏数下掺气坎的水力特性研究[D]. 昆明: 昆明理工大学, 2010.
- [16] WU J H, RUAN S P. Cavity length below chute aerators [J]. Science in China, 2008, 51(2): 170-178.
- [17] 崔巍, 陈文学, 王晓松, 等. 基于量纲分析的弧形闸门过流公式及其应用[J]. 灌溉排水学报, 2012, 31(5): 91-93. (CUI Wei, CHEN Wenxue, WANG Xiaosong, et al. Research progress on groundwater vulnerability assessment [J]. Journal of Irrigation and Drainage, 2012, 31(5): 91-93. (in Chinese))
- [18] HAWKINS D M. The problem of overfitting [J]. Cheminform, 2004, 35(19): 1-12.
- [19] NGOC T T, DAI L V, THUYEN C M. Support vector regression based on grid search method of hyperparameters for load forecasting [J]. Acta Polytechnica Hungarica, 2021, 18(2): 143-158.
- [20] LAREF R, LOSSON E, SAVA A, et al. On the optimization of the support vector machine regression hyperparameters setting for gas sensors array applications [J]. Chemometrics and Intelligent Laboratory Systems, 2018, 184(15): 22-27.
- [21] 牛景太. 基于奇异谱分析与 PSO 优化 SVM 的混凝土坝变形监控模型[J]. 水利水电科技进展, 2020, 40(6): 60-65. (NIU Jingtai. Dam deformation monitoring model based on singular spectrum analysis and SVM optimized by PSO [J]. Advances in Science and Technology of Water Resources, 2020, 40(6): 60-65. (in Chinese))
- [22] 王健峰, 张磊, 陈国兴, 等. 基于改进的网格搜索法的 SVM 参数优化[J]. 应用科技, 2012, 39(3): 28-31. (WANG Jianfeng, ZHANG Lei, CHEN Guoxing, et al. A parameter optimization method for an SVM based on improved grid search algorithm [J]. Applied Science and Technology, 2012, 39(3): 28-31. (in Chinese))

(收稿日期: 2021-09-17 编辑: 刘晓艳)