

免疫粒子群算法与支持向量机在枯水期 月径流预测中的应用

李月玉, 李磊

(云南省水利水电勘测设计研究院, 云南 昆明 650021)

摘要: 针对支持向量机(SVM)最佳算法参数难以确定以及基本粒子群算法(PSO)易陷入局部极值等不足, 提出免疫粒子群算法(IAPSO), 利用IAPSO算法搜寻SVM学习参数, 构建IAPSO-SVM预测模型, 并与PSO-SVM、GA-SVM模型作为对比, 以云南省某水文站枯水期月径流预测为例进行实例研究, 利用实例前43年和后10年资料对模型进行训练和预测。结果表明: IAPSO-SVM模型对实例后10年枯水期1-3月月均径流预测的平均相对误差绝对值分别为3.32%、6.52%和6.55%, 精度优于PSO-SVM和GA-SVM模型, 表明IAPSO-SVM模型具有较高的预测精度和泛化能力。IAPSO算法利用浓度选择机制及免疫接种原理, 改进了基本粒子群优化算法的全局寻优能力和收敛速度, 具有较强的全局寻优能力。利用IAPSO算法优化得到的SVM学习参数可有效提高SVM模型的预测精度和泛化能力。

关键词: 月径流; 径流预测; 免疫粒子群算法; 支持向量机; 参数优化; 枯水期

中图分类号: TV121.5; P333.1

文献标识码: A

文章编号: 1672-643X(2015)03-0124-05

Immune particle swarm algorithm and support vector machine in dry season monthly runoff prediction

LI Yueyu, LI Lei

(Yunnan Institute of Water & Hydropower Engineering Investigation Design Research, Kunming 650021 China)

Abstract: Aimed at the shortcomings of optimal algorithm parameters of support vector machine (SVM) being difficult to determine and basic particle swarm optimization algorithm (PSO) being easy to fall into local extreme and other issues, the paper proposed immune particle swarm optimization algorithm (IAPSO) by using IAPSO algorithm to search SVM learning parameters, constructed IAPSO-SVM forecast model, and compared it with PSO-SVM, GA-SVM mode. Taking monthly runoff forecast of a hydrological station in Yunnan province as an example, it trained and forecasted the model by using data before 43 years and after 10 years the station was built. The results show that the absolute values of average relative errors of prediction by use of IAPSO-SVM model in 3 months dry season after runoff instance of 10 years are 3.32%, 6.52% and 6.55%. The prediction accuracy by IAPSO-SVM model is better than that by PSO-SVM model and GA-SVM model. The result showed that IAPSO-SVM model has higher prediction accuracy and generalization ability. IAPSO algorithm used density selection mechanism and immunization theory to improve the global searching ability and convergence speed of basic particle swarm optimization algorithm, and has stronger global optimization ability. The SVM learn parameters got by using the IAPSO algorithm to optimize can effectively improve the prediction accuracy and generalization ability.

Key words: monthly runoff; runoff forecast; immune particle swarm algorithm; support vector machine; parameter optimization; dry season

收稿日期: 2014-11-08; 修回日期: 2014-12-06

作者简介: 李月玉(1983-), 女, 云南云龙人, 学士, 工程师, 主要从事水利水电工程水文分析与计算、水资源规划以及防洪评价等工作。

1 研究背景

提高枯水期月径流预测预报的精度对于合理调配水资源、缓解“三生”用水矛盾以及实行最严格水资源管理制度具有重要意义。目前枯水期径流预测方法主要有数理统计法、回归分析法、时间序列法、模糊数学法、灰色系统法以及神经网络法等,均在枯水期径流预测预报中取得了一定的效果,但由于枯水期径流受气候、下垫面条件等多种因素的制约和影响,对其的预测常表现出较大的随机性和不确定性,预测结果往往很难达到理想精度需求。

支持向量机(Support Vector Machines, SVM)是Cortes和Vapnik等人提出的一种新的机器学习方法,用于解决模式分类和非线性映射问题,其基础是Vapnik创建的统计学习理论(Statistical Learning Theory, SLT)和结构风险最小化(Structural Risk Minimization, SRM)准则。

SVM通过有限的样本信息,在模型的复杂性和学习能力之间寻求最佳折中,尤其在解决小样本、非线性及超高维等复杂问题中具有“理论全局最优”、“结构简单”和“克服维数灾问题”等诸多优势,已成为继人工神经网络(Artificial Neural Network, ANN)之后机器学习领域新的研究热点^[1-4]。然而,在实际应用中, SVM学习参数——惩罚因子 C 、核函数参数 g 和不敏感系数 ε 的选取对模型的预测精度有着关键性影响^[1]。惩罚因子 C 是在结构风险和样本误差之间作出折中, C 过小, 样本数据惩罚就小, 训练误差就增大; C 过大, 学习精度提高, 但模型的泛化能力变差。核函数参数 g 代表RBF带宽, g 越小, 拟合误差越小, 训练时间延长, 但过小的 g 会导致模型过拟合而降低模型的泛化能力; 不敏感系数 ε 用于控制模型的预测能力, 随着 ε 增加, 支持向量的个数会减少, 导致模型学习精度不够, 推广能力降低, 造成欠拟合; ε 过小, 不但增加训练时间, 而且可能导致模型过拟合而使推广能力下降^[3-5]。

目前用于SVM学习参数选取的方面有试凑法、经验选择法等人工方法, 实际应用中存在参数选取范围小、计算效率低、预测误差大等弊端^[1,6]。粒子群优化算法(Particle Swarm Optimization, PSO)是近年来发展起来的一种新的进化算法(Evolutionary Algorithms, EA), 同遗传算法(Genetic Algorithm, GA)类似, PSO通过迭代寻找最优解及适应度来评价解的优劣, 算法简单, 具有实现容易、精度高、收敛快等优点, 并被证明在大多数情况下比GA更有效^[7]。但基本

PSO在进化后期存在收敛速度慢、易陷入局部极值和寻优精度低等缺陷, 限制了它的应用。

本文鉴于基本PSO算法及SVM模型在实际应用中存在的不足, 将免疫原理引入PSO算法中, 提出了免疫粒子群优化算法(Immune Algorithm Particle Swarm Optimization, IAPSO)与支持向量机相融合的IAPSO-SVM预测模型, 利用IAPSO搜寻SVM惩罚因子 C 、核函数参数 g 和不敏感系数 ε , 构建PSO-SVM、GA-SVM模型作为对比, 以云南省某水文站枯水期1-3月月径流预测为例进行实例验证。验证结果表明IAPSO-SVM模型具有较好的预测精度和泛化能力。

2 IAPSO 算法介绍

2.1 粒子群算法

PSO是近年来发展起来的一种新型启发式进化算法, 最早由Kennedy和Eberhart于1995年受鸟群觅食过程中迁徙和群聚行为而提出的群体智能全局随机搜索算法, 具有简单、容易实现、收敛速度快和全局寻优等特点, 并被证明在大多数情况下比遗传算法(GA)更有效。PSO算法可描述为^[7]:

设在一个 S 维的搜索空间中, 由 n 个粒子组成的种群 $W = (W_1, W_2, \dots, W_n)$, 其中第 i 个粒子表示为一个 S 维的向量 $W_i = (w_{i1}, w_{i2}, \dots, w_{is})^T$, 代表第 i 个粒子在 S 维搜索空间中的位置, 表示一个问题的潜在解。根据目标函数可计算出每个粒子位置 W_i 所对应的适应度值, 并将第 i 个粒子的速度记为 $V_i = (V_{i1}, V_{i2}, \dots, V_{is})^T$, 其个体极值记为 $P_i = (P_{i1}, P_{i2}, \dots, P_{is})^T$, 种群全局的极值记为 $P_g = (P_{g1}, P_{g2}, \dots, P_{gs})^T$ 。在每一迭代过程中, 粒子通过个体极值和全局极值更新自身的速度和位置, 更新公式为:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - W_{id}^k) + c_2 r_2 (P_{gd}^k - W_{id}^k) \quad (1)$$

$$W_{id}^{k+1} = W_{id}^k + V_{id}^{k+1} \quad (2)$$

式中: ω 为惯性因子; $d = 1, 2, \dots, s$; $i = 1, 2, \dots, n$; k 为当前迭代次数; V_{id} 为粒子的速度; c_1 和 c_2 分别为自我学习因子和社会学习因子(统称加速因子); r_1 和 r_2 为分布于 $[0, 1]$ 之间的随机数。

2.2 免疫粒子群算法

免疫算法(Immune Algorithm, IA)是受生物免疫系统启发, 在免疫学理论上发展起来的一种新兴智能算法。IA利用免疫系统的多样性产生和维持机制来保持群体的多样性, 克服了一般寻优过

程尤其是多峰函数寻优过程中难处理的“早熟”问题^[8],具有种群多样性、免疫记忆、分布式并行处理和鲁棒性等优点。免疫粒子群优化算法(Immune Algorithm Particle Swarm Optimization, IAPSO)是将免疫系统的免疫信息处理机制引入 PSO 算法中,将待求解问题视为抗原,每一个抗体代表问题的一个解,同时每个抗体也即是粒子群中的一个粒子。抗原与抗体的亲和力由 PSO 算法中的适应度来衡量,反映了对目标函数以及约束条件的满足程度;抗体之间的亲和力则反映了粒子之间的差异,即种群的多样性。IAPSO 算法步骤简述如下^[9-11]:

Step1 初始化参数。包括种群规模 N 、最大迭代次数 $\max gen$ 、惯性权重 ω 、加速因子 c_1 和 c_2 、抗体相似系数 η 、适应度函数 $f(x)$ 、交叉率、变异率和疫苗接种概率等。

Step2 随机产生抗体(粒子)群 N , 初始化粒子群的位置和速度。计算每个粒子适应度值,将其适应度值与个体极值 $p_{best,i}(gen)$ 进行比较,保留最佳个体极值 $p_{best,i}(gen)$ 。

Step3 对每个粒子,将其适应度值与全局极值 $g_{best}(gen)$ 进行比较,保留最佳个体极值 $g_{best}(gen)$ 。

Step4 免疫操作。定义最优粒子和任意粒子 i 的亲和力 A_i :

$$A_i = \frac{1}{1 + t_i} \tag{3}$$

$$t_i = \frac{f(x_i) - f_{\min}(x)}{f_{\max}(x) - f(x_i) + \sigma} \tag{4}$$

式中: $f(x)$ 是评价粒子的适应度函数; σ 为避免分母为 0 而取的正小数。

定义 C 为种群浓度,计算公式为:

$$C = \frac{\sum_{i=1}^N g(i)}{N} \tag{5}$$

$$g(i) = \begin{cases} 1, & A_i > \delta \\ 0, & A_i \leq \delta \end{cases} \tag{6}$$

式中: δ 为抑制半径, $\delta \in (0, 1]$ 。

根据 A_i 、 C 定义粒子 i 被选择的概率 P_i :

$$P_i = \alpha \frac{A_i}{\sum_{i=1}^N A_i} + (1 - \alpha) \frac{1}{N} \exp(-\frac{C}{\beta}) \tag{7}$$

$\alpha, \beta \in (0, 1)$ 。

Step5 按照式(1)、式(2)更新每个粒子的速度和位置。

Step6 利用式(7)产生的免疫“疫苗”对群体进

行免疫操作,计算接种疫苗后每个粒子的适应度值,并根据适应度值进行免疫选择,如果适应值减少,则保留该粒子;否则取消疫苗。

Step7 更新群体的个体极值 $p_{best,i}(gen)$ 与全局极值 $g_{best}(gen)$ 。

Step8 判断是否满足结束条件,如果迭代次数大于最大迭代次数,则算法结束,输出结果;否则转到 Step3。

2.3 支持向量机

支持向量机(SVM)回归是通过核函数将低维空间中非线性回归问题映射到高维特征空间,然后在这个特征空间中求解凸优化问题,实现某一非线性变换后的线性回归,在计算复杂度未增加的情况下利用线性空间的方法解决非线性问题,较好解决了小样本、非线性、高维度、局部极小值等问题。目前利用 SVM 进行回归运算已有较多研究,本文简述 SVM 回归算法原理如下^[3-4,12]:

设含有 l 个训练样本的集合为: $\{(x_i, y_i), i = 1, 2, \dots, l\}$, 其中, $x_i (x_i \in R^d)$ 是第 i 个训练样本的输入列向量, $x_i = [x_i^1, x_i^2, \dots, x_i^d]^T$, $y_i \in R$ 为对应输出值。SVM 回归用核函数将数据映射到高维特征空间,再在高维特征空间中进行线性回归,依据结构风险化最小化原则,将其学习过程转换为凸优化问题,即:

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\ \text{s. t.} \begin{cases} y_i - w\Phi(x_i) - b \leq \varepsilon + \xi_i \\ -y_i + w\Phi(x_i) + b \leq \varepsilon + \xi_i^*, \\ i = 1, 2, \dots, l \\ \xi_i \geq 0, \xi_i^* \geq 0 \end{cases} \end{cases} \tag{8}$$

式中: $\Phi(x)$ 为非线性映射函数; ε 为线性不敏感损失函数; ξ_i, ξ_i^* 为松弛变量; C 为惩罚因子。

其回归方程最终表述为:

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) K(x_i, x_j) + b \tag{9}$$

式中: $K(x_i, x_j) = \Phi(x_i) \Phi(x_j)$ 为满足 Mercer 条件的核函数; a_i^*, a_i 为二次规划中 Lagrange 乘子。

其中:

$$b = \frac{1}{N_{nsv}} \left\{ \sum_{0 < a_i < C} [y_i - \sum_{x_j \in SV} (a_i - a_i^*) K(x_i, x_j) - \varepsilon] + \sum_{0 < a_i < C} [y_i - \sum_{x_j \in SV} (a_i - a_i^*) K(x_i, x_j) + \varepsilon] \right\} \tag{10}$$

式中: N_{nsv} 为支持向量机个数。

常用的核函数主要类型有线性核函数 ($K(x, x_i) = x^T x_i$)、多项式核函数 ($K(x, x_i) = (gx^T x_i +$

$r)^p, g > 0)$ 、径向基核函数($K(x, x_i) = \exp(-g \| x - x_i \|^2), g > 0)$ 和两层感知核函数($K(x, x_i) = \tanh(gx^T x_i + r)$)。核函数可以看成是实际问题的特征提取过程,核函数的合理选取有助于提高模型精度。本文选择径向基核函数作为 SVM 核函数。

2.4 IAPSO – SVM 预测模型

定义适应度(目标)函数:

$$\begin{cases} \min f(C, g, \varepsilon) = \frac{1}{n} \sum_{i=1}^N (y_i - \hat{y})^2 \\ \text{s. t } C \in [C_{\min}, C_{\max}], g \in [g_{\min}, g_{\max}], \\ \varepsilon \in [\varepsilon_{\min}, \varepsilon_{\max}] \end{cases} \quad (11)$$

式中: y_i 为第 i 个样本实测值; $\hat{y}_i$ 为第 i 个样本模拟值,可由(9)计算得到。SVM 模型参数优化的思想就是通过迭代算法搜寻一组参数 (C, g, ε) , 通过 SVM 学习使适应度函数式(11)达到最小。

本文选取式(11)作为适应度函数,利用 IAPSO 算法对参数 (C, g, ε) 进行寻优。具体算法步骤为:
Step1 初始化参数。选取 SVM 模型训练样本和

检验样本,进行样本归一化处理,设定惩罚因子 C 、核函数参数 g 和不敏感系数 ε 的搜寻范围以及 IAPSO 算法的种群规模 N 、最大迭代次数 maxgen、惯性权重 ω 、加速因子 c_1 和 c_2 、抗体相似系数 η 、交叉率、变异率和疫苗接种概率等。确定式(11) 为优化目标适应度函数 $f(x)$ 。

Step2 迭代寻优操作。按上述 IAPSO 算法步骤中的 Step2 ~ Step8 进行最优粒子(抗体)和全局极值寻优。

Step3 预测。获得最优粒子(抗体)对应的 (C, g, ε) 值,将其作为 SVM 的最佳学习参数对预测样本进行预测。

3 应用实例

3.1 数据来源与分析

利用 SPSS 软件分析云南省某水文站 1952 – 2005 年上年度月径流与次年度枯水期 1 – 3 月月径流相关关系,见下表 1。

表 1 上年度 1 – 12 月与次年 1 – 3 月月均流量相关系数

月份	1	2	3	4	5	6	7	8	9	10	11	12	次年 1 月	次年 2 月
次年 1 月	0.263	0.288	0.311	0.515 **	0.205	0.213	0.347	0.676 **	0.561 **	0.688 **	0.694 **	0.914 **		
次年 2 月	0.208	0.239	0.234	0.461 *	0.239	0.217	0.288	0.608 **	0.545 **	0.634 **	0.583 **	0.864 **	0.832 **	
次年 3 月	0.222	0.248	0.193	0.366	0.137	0.110	0.177	0.545 **	0.436 *	0.498 *	0.492 *	0.737 **	0.800 **	0.842 **

注:“**”表示在 0.01 水平(双侧)上显著相关;“*”表示在 0.05 水平(双侧)上显著相关。

从表 1 可以看出,该站上年度月径流与次年度枯水期 1 – 3 月月径流相关系数在 0.110 ~ 0.914 之间。本文选取 0.05 水平(双侧)上显著相关的上年度 4 月、8 – 12 月月均径流作为影响因子预测次年枯水期 1 月月均径流量;选取上年度 4 月、8 – 12 月及次年 1 月月均径流作为影响因子预测次年枯水期 2 月月均径流量;选取上年度 8 – 12 月及次年 1 – 2 月月均径流作为影响因子预测次年枯水期 3 月月均径流量。并以 1952 – 1994 年 43 a 实测月均径流作为训练样本,1995 – 2004 年 10 a 实测月均径流作为预测样本。

利用式(12)对该站各径流序列进行归一化处理:

$$\hat{x} = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (12)$$

式中: $\hat{x}$ 为经过标准化处理的数据; x 为原始数据; $x_{\max}$ 和 $x_{\min}$ 分别为数据序列中的最大数和最小数。

3.2 模型构建及参数设置

(1)模型构建。本文基于 MatlabR2011b 软件环境及 libsvm 工具箱编程分别构建 6 输入 1 输出、7

输入 1 输出和 7 输入 1 输出的枯水期 1、2 和 3 月月径流的 IAPSO – SVM、PSO – SVM 和 GA – SVM 预测模型,并选取平均相对误差绝对值 MRE 、最大相对误差绝对值 $\max RE$ 和最优适应度值 $\text{Best}MSE$ 对各模型的预测效果进行评价,公式如下:

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100 \quad (13)$$

$$\max RE = \max_{1 \leq i \leq n} \frac{|\hat{y}_i - y_i|}{y_i} \times 100 \quad (14)$$

$$\text{best } MRE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (15)$$

式中: $\hat{y}_i$ 为第 i 个样本预测值; y_i 为第 i 个样本实测值; $i = 1, 2, \dots, n, n$ 为预测样本数。

(2)参数设置。为了便于模型间性能的比较, IAPSO – SVM、PSO – SVM 和 GA – SVM 模型相同参数设置如下:均选择径向基函数作为核函数,最大迭代次数 maxgen = 200、群体规模 $N = 30$ 、惩罚因子 C 、核函数参数 g 和不敏感系数 ε 的搜索空间分别设为 0.001 ~ 1000、0.001 ~ 1000 和 0.001 ~ 0.1,交叉验

证参数 $V = 5$ 。其中 IAPSO - SVM 模型 $\alpha = \beta = 0.5$, $\sigma = 0.8, \delta = 0.5, \omega = 0.728$, 局部和全局搜索学习因子 $c_1 = 1.5, c_2 = 1.7$; PSO - SVM 模型惯性因子 $\omega = 0.728$, 局部和全局搜索学习因子 $c_1 = 1.5, c_2 = 1.7$; GA - SVM 模型交叉系数 $\theta = 0.9$, 变异系数 γ

$= 0.09$ 。
3.3 算法寻优效果及模型预测效果评价分析
应用 IAPSO - SVM、PSO - SVM 和 GA - SVM 模型分别对某水文站枯水期 1 - 3 月月径流进行预测, 预测结果见表 2。

表 2 某站枯水期 1 - 3 月月径流预测结果 %

年份	IAPSO - SVM 模型			PSO - SVM 模型			GA - SVM 模型		
	相对误差			相对误差			相对误差		
	1 月	2 月	3 月	1 月	2 月	3 月	1 月	2 月	3 月
1996	-5.62	-2.71	2.95	-5.26	-2.49	2.38	-3.18	-2.47	-10.90
1997	-2.44	6.33	13.38	0.71	6.23	16.33	-1.30	6.16	4.45
1998	-1.77	-5.82	6.91	-2.47	-9.06	8.50	5.61	-9.14	5.09
1999	2.92	-3.39	4.86	3.06	-5.74	4.99	-5.50	-5.85	11.69
2000	-0.82	7.13	11.53	1.21	15.38	12.99	1.21	15.20	-18.36
2001	1.93	12.50	-5.72	2.15	11.68	-1.84	3.55	11.66	-8.71
2002	9.97	14.91	12.35	12.08	14.58	15.53	10.18	14.45	-14.86
2003	-2.86	-2.01	0.36	1.30	-4.86	9.56	5.32	-5.06	-5.75
2004	-1.97	2.27	-7.37	-2.80	-0.21	-3.51	-7.18	-0.45	-6.60
2005	-2.86	-8.17	0.09	-4.86	-11.55	-0.29	-5.37	-11.76	5.81
MRE	3.32	6.52	6.55	3.59	8.18	7.59	4.48	8.21	9.22
max RE	9.97	14.91	13.38	12.08	15.38	16.33	10.18	15.20	18.36
best MSE	0.02872	0.02016	0.05657	0.03064	0.02125	0.06674	0.03111	0.02108	0.06349
best C	21.8266	51.1026	19.8844	63.6779	788.1479	39.7055	95.5514	826.7328	906.9624
best g	0.01	0.01	0.01	0.001	0.001	0.001	0.2375	0.001	0.81066
best ε	0.1	0.1	0.03610	0.1	0.06802	0.1	0.07239	0.06703	0.01427

从表 2 可以看出, IAPSO - SVM 模型对某水文站 1996 - 2005 年 1 - 3 月月均径流预测的 MRE 分别为 3.32%、6.52%、6.55%, $\max RE$ 分别为 9.97%、14.91%、13.38%, $\text{best} MSE$ 分别为 0.02872、0.02016、0.05657, 精度均优于 PSO - SVM 和 GA - SVM 模型, 表明 IAPSO - SVM 模型具有较好的预测精度和泛化能力。

4 结 语

在分析了 SVM 学习参数对模型精度的影响以及基本 PSO 算法在实际应用中存在的问题, 将免疫原理引入 PSO 算法中, 提出 IAPSO 算法, 利用 IAPSO 优化算法搜寻 SVM 模型最优惩罚因子 C 、核函数参数 g 和不敏感系数 ϵ , 提出 IAPSO - SVM 预测模型, 以云南省某水文站枯水期 1 - 3 月月均径流预测为例进行研究, 结果表明:

(1) 将免疫原理引入 PSO 算法中, 利用免疫记

忆与自我调节机制保证 PSO 算法的种群多样性, 有效提高了 PSO 算法的全局寻优能力和收敛性能。利用 IAPSO 算法寻优 SVM 学习参数, 实现了 SVM 模型惩罚因子 C 、核函数参数 g 和不敏感系数 ϵ 的自动确定, 提高了 SVM 模型的预测精度和泛化能力。

(2) 从实例 10 年枯水期 1 - 3 月月径流预测结果来看, IAPSO - SVM 模型 1 - 3 月预测的相对误差分别在 -5.62% ~ 9.97%、-8.17% ~ 14.91%、-7.37% ~ 13.38% 之间, 表明 IAPSO - SVM 模型具有较好的预测精度和泛化能力, 该模型可以用于枯水期月径流预测预报。

参考文献:

[1] 王 雷. 支持向量机在汽轮机状态监测中的应用[M]. 北京: 北京师范大学出版社, 2012.
[2] 崔东文. 基于多元变量组合的回归支持向量机集成模型及其应用[J]. 水利水运工程学报, 2014(2): 66 - 73.

(下转第 135 页)

- [18] Shi Lina., Lin Yuman, Zhang Xin, et al. Synthesis, characterization and kinetics of bentonite supported nZVI for the removal of Cr(VI) from aqueous solution[J]. Chemical Engineering Journal, 2011, 171(2): 612 – 617.
- [19] Ling Xiaofeng, Li Jiansheng, Zhu Wen, et al. Synthesis of nanoscale zero-valent iron/ordered mesoporous carbon for adsorption and synergistic reduction of nitrobenzene[J]. Chemosphere, 2012, 87(6): 655 – 660.
- [20] Yuan Songhu, Zheng Zhonghua, Meng Xiangzhou, et al. Surfactant mediated HCB dechlorination in contaminated soils and sediments by micro and nanoscale Cu/Fe particles[J]. Geoderma, 2010, 159(1–2): 165 – 173.
- [21] Shih Yang – hsin, Chen Yao – Cyong, Chen Mengyi, et al. Dechlorination of hexachlorobenzene by using nanoscale Fe and nanoscale Pd/Fe bimetallic particles[J]. Colloids and Surface A: Physicochemical and Engineering Aspects, 2009, 332(2–3): 84 – 89.
- [22] Zhu Nairuo, Luan Hongwei, Yuan Songhu, et al. Effective dechlorination of HCB by nanoscale Cu/Fe particles[J]. Journal of Hazardous Material, 2010, 176(1–3): 1101 – 1105.
- [23] Nie Xiaoqin, Liu Jianguo, Zeng Xianwei, et al. Rapid degradation of hexachlorobenzene by micron Ag/Fe bimetal particles[J]. Journal of Environmental Sciences, 2013, 25(3): 473 – 478.
- [24] Shih Yang – hsin, Chen Mengyi, Su Yuh – Fan. Pentachlorophenol reduction by Pd/Fe bimetallic nanoparticles: Effects of copper, nickel, and ferric cations[J]. Applied Catalysis B, 2011, 105(1–2): 24 – 29.

(上接第128页)

- [3] 崔东文. 支持向量机在湖库营养状态识别中的应用[J]. 水资源保护, 2013, 29(4): 26 – 30.
- [4] 崔东文. 支持向量机在水资源类综合评价中的应用——以全国31个省级行政区水资源合理性配置为例[J]. 水资源保护, 2013, 29(5): 20 – 27.
- [5] 孙宇星, 关伟, 葛昱, 等. 基于支持向量机方法的轨道交通乘客旅行时间短时预测方法研究[J]. 系统工程理论与实践, 2014, 34(6): 1587 – 1592.
- [6] 孙俊, 王艳, 金夏明, 等. 基于 MSCPSO 混合核 SVM 参数优化的生菜品质检测[J]. 农业机械学报, 2013, 44(9): 209 – 213 + 218.
- [7] 史峰, 王辉, 郁磊, 等. Matlab 智能算法 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2011.
- [8] 向波, 纪昌明, 罗庆松. 免疫粒子群算法及其在水库优化调度中的应用[J]. 河海大学学报(自然科学版), 2008, 36(2): 198 – 202.
- [9] 邓丽, 蒋婧, 费敏锐. 基于免疫粒子群算法的 PID 参数整定与自适应[J]. 自动化仪表, 2013, 34(2): 65 – 67 + 71.
- [10] 段富, 苏同芬. 免疫粒子群算法的改进及应用[J]. 计算机应用, 2010, 30(7): 1883 – 1884 + 1888.
- [11] 周钰婷, 刘光远, 赖祥伟. 模拟退火免疫粒子群算法在皮肤电信号情感识别中的应用[J]. 计算机应用, 2011, 31(10): 2814 – 2817.
- [12] 刘伟, 王建平, 刘长虹, 等. 基于粒子群寻优的支持向量机番茄红素含量预测[J]. 农业机械学报, 2012, 43(4): 143 – 147, 155.