

# 基于工艺参数的 7005 铝合金力学性能的支持向量回归预测

蔡从中, 温玉锋, 朱星键, 裴军芳, 王桂莲, 肖婷婷

(重庆大学 应用物理系, 重庆 400044)

**摘要:** 根据 7005 铝合金在不同工艺参数(挤压温度、挤压速度、淬火方式和时效条件)下的力学性能(抗拉强度  $\sigma_b$ 、屈服强度  $\sigma_{0.2}$  和硬度 HB)实测数据集, 应用基于粒子群算法(PSO)寻优的支持向量回归(SVR)结合留一交叉验证(LOOCV)的方法, 对 7005 铝合金力学性能进行建模和预测研究, 并与偏最小二乘法(PLS)、反向传播人工神经网络(BPNN)和两者结合的 PLS-BPNN 模型的预测结果进行比较。结果表明: 基于 SVR-LOOCV 法的预测精度最高, 对 3 种力学性能( $\sigma_b$ 、 $\sigma_{0.2}$  和 HB)预测的均方根误差(RMSE)分别为 4.531 9 MPa、14.550 8 MPa 和 HB1.414 2, 其平均相对误差(MRE)分别为 0.72%、2.61% 和 0.66%, 均比 PLS、BPNN 和 PLS-BPNN 方法预测的 RMSE 和 MRE 要小。

**关键词:** 7005 铝合金; 力学性能; 支持向量机; 粒子群算法; 留一交叉验证法; 回归分析

中图分类号: TP18; TG146.2+1

文献标识码: A

## Quantitative prediction of mechanical properties of 7005 Al alloys from processing parameters via support vector regression

CAI Cong-zhong, WEN Yu-feng, ZHU Xing-jian, PEI Jun-fang, WANG Gui-lian, XIAO Ting-ting

(Department of Applied Physics, Chongqing University, Chongqing 400044, China)

**Abstract:** The support vector regression (SVR) approach based on the particle swarm optimization (PSO) for its parameter optimization, combined with leave-one-out cross validation (LOOCV), was proposed to predict the mechanical properties (tensile strength  $\sigma_b$ , yield strength  $\sigma_{0.2}$  and hardness HB) of 7005 Al alloys under different processing parameters including extrusion temperature, extrusion velocity, quenching type and aging time. The results strongly support that the prediction precision of SVR-LOOCV method is superior to those of partial least squares (PLS), back-propagation neural networks (BPNN) and their combination PLS-BPNN model by applying the identical dataset. The root mean square errors (RMSE) for  $\sigma_b$ ,  $\sigma_{0.2}$  and HB achieved by SVR-LOOCV are 4.531 9 MPa, 14.550 8 MPa and HB 1.414 2, respectively, and their mean relative errors (MRE) are 0.72%, 2.61% and 0.66%, respectively, which are less than those predicted by PLS, BPNN or PLS-BPNN approach.

**Key words:** 7005 Al alloys; mechanical properties; support vector machines; particle swarm optimization; leave-one-out cross validation; regression analysis

7005 铝合金是 Al-Zn-Mg 合金系列中的一种中高强度合金。该合金不仅具有密度小、无磁性、散热效果好等特点, 而且具有相当高的强度、断裂韧性, 还呈现出良好的抗腐蚀性、可焊性、热稳定性和机械加

工性能。目前, 7005 铝合金作为一种结构材料被广泛地应用于运输工具、桥梁、升降机、液压设备等领域。抗拉强度、屈服强度和硬度是铝合金材料力学性能的 3 个主要参数, 而力学性能是铝合金的一个极其重要

基金项目: 教育部新世纪优秀人才支持计划资助项目(NCET-07-0903); 教育部留学回国人员科研启动基金资助项目(教外司留[2008]101-1); 重庆市自然科学基金资助项目(CSTC2006BB5240); 国家大学生创新性实验计划资助项目(CQUCX-G-2007-016)

收稿日期: 2009-03-27; 修订日期: 2009-05-27

通信作者: 蔡从中, 研究员, 博士; 电话: 13996438540; E-mail: caiczh@gmail.com

的性能指标。因此,在生产铝合金的工艺过程中,通过建立加工工艺参数与其力学性能关系的预测模型,对于准确估计该铝合金的力学性能具有十分重要的指导意义。到目前为止,已有人利用偏最小二乘(PLS)、反向传播神经网络(BPNN)及其与 PLS 相结合的 PLS-BPNN 等方法建立了铝合金的力学性能预测模型<sup>[1]</sup>,尽管这些方法能较好地预测铝合金的力学性能,但它们的预测精度还不够高,泛化能力也不够理想。因此,进一步探索和寻求更加准确、有效的理论预测方法很有必要。

支持向量机(Support vector machine, 简称 SVM)是由 VAPNIK 等<sup>[2]</sup>和 HUANG<sup>[3]</sup>等提出的一种基于结构风险最小化的统计学习方法。该方法可用于分类和回归分析,已被成功地应用于很多实际领域,如文本分类及手写体数字识别<sup>[2,4]</sup>、语音识别<sup>[5]</sup>、商业时序预报<sup>[6]</sup>、水文预报<sup>[7]</sup>、地球空间物理及实验高能物理数据分析与处理<sup>[8]</sup>、计算机辅助药物设计<sup>[9]</sup>、蛋白质结构和功能预测<sup>[10-12]</sup>、材料性能预测<sup>[13-14]</sup>等。本文作者利用文献[1]报道的 7005 铝合金在不同的挤压淬火工艺和随后的时效工艺下的力学性能实验数据集,应用基于粒子群(Particle swarm optimization, PSO)算法进行参数寻优的支持向量回归(Support vector regression, SVR)方法,结合留一交叉验证法(Leave-one-out cross validation, LOOCV),对不同加工工艺参数下的 7005 铝合金的力学性能进行建模和预测研究,并与文献[1]中应用 PLS、BPNN 以及 PLS-BPNN 的预测结果进行比较。

## 1 SVR 方法简介

### 1.1 SVR 原理

设样本集为 $(x_1, y_1), \dots, (x_m, y_m)$ , 寻找一个输入空间到输出空间的非线性映射  $\Phi$ , 通过该映射, 将样本集中的数据  $x$  映射到高维空间  $F$ , 并在特征空间  $F$  中用下述函数进行线性回归:

$$f(x) = w \cdot \Phi(x) + b, \Phi: R^n \rightarrow F, w \in F \quad (1)$$

式中:  $b$  是阈值,  $w$  是回归系数向量。影响  $w$  的因素有: 经验风险的总和以及使其在高维空间平坦的  $\|w\|^2$ , 即:

$$R(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m L_\varepsilon(f(x_i) - y_i) \quad (2)$$

$$L_\varepsilon(f(x_i) - y_i) = \begin{cases} 0, & (|f(x_i) - y_i| < \varepsilon) \\ |f(x_i) - y_i| - \varepsilon, & (|f(x_i) - y_i| \geq \varepsilon) \end{cases} \quad (3)$$

式中:  $m$  表示训练样本个数,  $L_\varepsilon(f(x_i) - y_i)$  是损失函数,

$C$  是惩罚因子,  $\varepsilon$  是误差。

为控制函数的复杂性, 应使线性回归函数尽量平坦, 并考虑可能超出精度  $\varepsilon$  的回归误差, 引入松弛因子  $\xi$  和  $\xi^*$ , 以处理不满足式(3)的数据点。根据统计学习理论的结构风险最小化准则, SVR 通过极小化目标函数  $R(w, \xi, \xi^*)$  来确定式(1)中的  $w$  和  $b$ :

$$R(w, \xi, \xi^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad (4)$$

$$\text{且满足: } \begin{cases} y_i - w \cdot x_i - b & \varepsilon + \xi_i \\ w \cdot x_i + b - y_i & \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* & 0 \end{cases}$$

式(4)中, 第一项是使回归函数更为平坦, 泛化能力更好, 第二项则为减少误差, 惩罚因子  $C$  是一个常数, 且  $C > 0$ , 用来控制对超出误差  $\varepsilon$  的样本的惩罚程度。为求解  $w$  和  $b$ , 建立拉格朗日方程:

$$\begin{aligned} L(w, \xi, \xi^*) = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) - \\ & \sum_{i=1}^m \alpha_i \{(\varepsilon + \xi_i) + y_i + [w \cdot \Phi(x_i)] + b\} - \\ & \sum_{i=1}^m \alpha_i^* \{(\varepsilon + \xi_i^*) + y_i + [w \cdot \Phi(x_i)] - b\} - \\ & \sum_{i=1}^m (\lambda_i \xi_i + \lambda_i^* \xi_i^*) \end{aligned} \quad (5)$$

要使式(5)取得最小值,  $L$  对于参数  $w$ 、 $b$ 、 $\xi_i$  和  $\xi_i^*$  的偏导数都应等于零。即:

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot \Phi(x_i) = 0$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \lambda_i = 0$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \alpha_i^* - \lambda_i^* = 0 \quad (6)$$

将式(6)代入式(5), 可以得到对偶优化问题:

$$\begin{aligned} \min & \left\{ \frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)(\Phi(x_i) \cdot \Phi(x_j)) + \right. \\ & \left. \sum_{i=1}^m \alpha_i (\varepsilon - y_i) + \sum_{i=1}^m \alpha_i^* (\varepsilon + y_i) \right\} \end{aligned} \quad (7)$$

$$\text{且满足: } \begin{cases} \sum_{i=1}^m (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases}$$

由此, SVR 的函数回归就可以归结为求解二次规划问题式(7), 从而可得到用训练样本点表示的  $w$ :

$$w = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \Phi(x_i) \quad (8)$$

式中:  $\alpha_i$  和  $\alpha_i^*$  是最小化  $R(w, \zeta_i, \zeta_i^*)$  的解。由此可求得线性回归函数:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) k(x, x_i) + b \quad (9)$$

式中:  $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$  为核函数。选择不同形式的核函数就可以生成不同的 SVR 回归模型。常用的核函数有: 径向基函数、多项式核函数、Sigmoid 核函数、线性核函数等。本文采用径向基函数来建立 SVR 模型。

## 1.2 SVR 回归参数的 PSO 算法寻优

PSO 是于 1995 年由 KENNEDY 和 EBERHART<sup>[15]</sup> 模拟鸟群的飞行捕食行为而提出的一种高效多维并行寻优算法。由于 SVR 回归模型的泛化性能依赖于误差  $\varepsilon$ 、误差惩罚因子  $C$  和核函数参数  $\gamma$  等 3 个参数, 因此, 对  $(\varepsilon, C, \gamma)$  参数进行寻优显得十分关键。本研究采用 PSO 算法来寻找参数  $(\varepsilon, C, \gamma)$  的最优值, 即采用速度-位置搜索模型来寻找最优参数。设群体中的每个粒子由 3 维参数向量  $(\varepsilon, C, \gamma)$  组成, 第  $i$  个粒子在 3 维解空间的位置为  $u_i = (u_{i1}, u_{i2}, u_{i3})^T$ , 其速度为  $v_i = (v_{i1}, v_{i2}, v_{i3})^T$ , 当前时刻的个体极值记为  $p_{ibest}$ , 全局极值记为  $g_{best}$ 。在每次迭代中, 粒子跟踪个体极值、全局极值和自己前一个时刻的状态来调整当前时刻的位置和速度, 迭代公式如下<sup>[16]</sup>:

$$v_i(t+1) = \omega v_i(t) + c_1 \text{rand}() (p_{ibest} - u_i(t)) + c_2 \text{rand}() (g_{best} - u_i(t)) \quad (10)$$

$$u_i(t+1) = u_i(t) + v_i(t+1) \quad (11)$$

式中:  $v(t)$ 、 $v(t+1)$ 、 $u(t)$  和  $u(t+1)$  分别是粒子在当前时刻、下一时刻的速度和位置;  $\text{rand}()$  是  $[0, 1]$  之间的随机数;  $c_1$  和  $c_2$  是学习因子, 通常取为 2;  $\omega$  是权重因子, 为加快收敛速度, 其值应随算法迭代的进行而自动调节, 一般定义为

$$\omega = \omega_{\min} + (N_{\max} - N)(\omega_{\max} - \omega_{\min}) / N_{\max} \quad (12)$$

式中:  $\omega_{\max}$  和  $\omega_{\min}$  分别为最大和最小权重因子,  $N$  为

当前迭代次数,  $N_{\max}$  为总的迭代次数, 且  $\omega_{\max}$  和  $\omega_{\min}$  的值一般取为 0.9 和 0.4。为了直接反映 SVR 模型的回归性能, 选用均方根误差 (RMSE) 作为适应度函数:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (13)$$

式中:  $m$  是训练样本数,  $y_i$  和  $\hat{y}_i$  分别是第  $i$  个训练样本目标量的实测值和预测值。

## 2 SVR 回归模型的建立

### 2.1 不同加工工艺参数下的 7005 铝合金力学性能实测数据集

本研究所用数据 (见表 1) 来源于文献 [1]。方善锋等<sup>[1]</sup> 针对 26 个  $Al_{3.24}Zn_{1.7}Mg_{0.32}Fe$  合金样本, 采用正交实验设计方法, 测量在不同的挤压温度、挤压速度、淬火方式和时效条件等 4 个加工工艺参数下合金的抗拉强度  $\sigma_b$ 、屈服强度  $\sigma_{0.2}$  和硬度 HB 值, 由此得到该数据集。文献 [1] 利用 PLS、BPNN 以及 PLS-BPNN, 采用 LOOCV 法对不同工艺参数下合金的  $\sigma_b$ 、 $\sigma_{0.2}$  和 HB 值进行预测和对比研究。

### 2.2 模型的建立

为便于与文献 [1] 中的 PLS、BPNN 以及 PLS-BPNN 方法的预测效果进行直接比较, 本研究应用 SVR 结合 LOOCV 法对数据集中的 26 个样本进行了建模训练与预测研究, 即以挤压温度、挤压速度、淬火方式和时效条件等 4 个参数为输入变量, 以合金的  $\sigma_b$ 、 $\sigma_{0.2}$  和 HB 为输出变量, 依序每次取出 1 个样本为测试样本, 其余样本为训练样本, 以这种方式进行 26 次的 SVR 建模和预测。

### 2.3 模型预测性能的评价

采用平均相对误差 (MRE)、均方根误差 (RMSE) 和相关系数 ( $R^2$ ) 对所建模型的预测性能进行评价。其中,  $MRE$  和  $R^2$  分别定义如下:

$$MRE = \frac{1}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right| \quad (14)$$

$$R^2 = \frac{\sum_{j=1}^n (\hat{y}_j - \bar{y})^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \quad (15)$$

式中:  $n$  是检验样本数,  $y_j$  和  $\hat{y}_j$  分别是第  $j$  个检验样本的目标值和预测值,  $\bar{y}$  是检验样本的目标平均值。

表1 不同加工工艺参数下的7005铝合金力学性能实测值<sup>[1]</sup>

Table 1 Experimental data of mechanical properties of 7005 Al alloy under different processing parameters

Sample No.	Extrusion temperature /	Extrusion velocity / (m·min <sup>-1</sup> )	Quenching type	Aging time (155 )/h	$\sigma_b$ /MPa	$\sigma_{0.2}$ /MPa	HB
1	460	1	2	16	325	240	87
2	460	1	1	16	315	220	85
3	460	5	2	16	305	200	85
4	460	3	1	16	285	169	78
5	480	1	2	16	310	225	85
6	480	1	1	16	295	215	82
7	480	3	2	16	310	235	84
8	480	5	2	16	300	215	85
9	500	1	2	16	305	220	83
10	500	1	1	16	290	295	82
11	500	3	2	16	285	205	79
12	500	5	1	16	290	220	82
13	460	1	2	4	345	245	97
14	460	1	1	4	345	235	97
15	460	5	2	4	350	220	96
16	460	3	1	4	370	220	102
17	480	1	2	4	330	230	91
18	480	1	1	4	335	230	93
19	480	3	2	4	325	230	91
20	500	5	1	4	325	220	90
21	460	1	2	8	345	260	94
22	460	1	1	8	345	255	93
23	460	5	2	8	340	235	95
24	460	3	1	8	345	220	97
25	480	1	1	8	310	225	85
26	500	5	1	8	300	220	82

### 3 结果分析与讨论

表2 所列为应用 SVR-LOOCV 对 7005 铝合金力学性能数据集的预测结果及其相对误差。为了便于直接比较,表2 中同时还列出了文献[1]中 PLS-BPNN 的 LOOCV 的预测结果及相对误差。表3 所列为 PLS、BPNN、PLS-BPNN 和 SVR 的预测性能的统计结果。

由表2 可见,SVR-LOOCV 对合金的  $\sigma_b$ 、 $\sigma_{0.2}$  和 HB 的预测结果中,绝大多数样本(24/26=92.31%、20/26=76.92%和 24/26=92.31%)预测结果的相对误差均小于 3%,而对于同样应用 LOOCV 的 PLS、BPNN 和 PLS-BPNN 等 3 种模型中预测效果最好的

PLS-BPNN,其预测的相对误差不超出 3%的样本数分别只有 22、9 和 20,均低于 SVR-LOOCV 的预测结果;SVR-LOOCV 法预测结果中,相对/绝对误差为 0 的样本数分别达到了 18、13 和 20,而基于 LOOCV 的 PLS-BPNN 预测的相对/绝对误差为 0 的样本数分别只有 1、2 和 5 个,远不及 SVR-LOOCV 法预测效果。

由表3 可见,对于 PLS、BPNN、PLS-BPNN 和 SVR 等 4 种不同的回归预测方法,预测能力依次增强。7005 铝合金的 3 种力学性能( $\sigma_b$ 、 $\sigma_{0.2}$  和 HB)经 SVR 预测的均方根误差(RMSE)和平均相对误差(MRE),分别为 4.531 9 MPa、14.550 8 MPa 和 HB1.414 2 以及 0.7225%、2.6070%和 0.6561%,与 PLS、BPNN 和 PLS-BPNN 法的预测结果相比,均为最小。这表明:SVR-LOOCV 法的预测精度比其它 3 种方法的要高,

表 2 7005 铝合金力学性能实验值与用 LOOCV 法的 PLS-BPNN 和 SVR 模型预测结果

Table 2 Measured values and predicted results of mechanical properties of 7005 Al alloys using PLS-BPNN and SVR models via LOOCV

Sample No.	$\sigma_b$ /MPa					$\sigma_{0.2}$ /MPa					HB				
	Exp.	PLS-BPNN <sup>[1]</sup>	RE/%	SVR	RE/%	Exp.	PLS-BPNN <sup>[1]</sup>	RE/%	SVR	RE/%	Exp.	PLS-BPNN <sup>[1]</sup>	RE/%	SVR	RE/%
1	325	322	-0.92	320	-1.54	240	236	-1.67	240	0.00	87	88	1.15	87	0.00
2	315	313	-0.63	315	0.00	220	213	-3.18	220	0.00	85	86	1.18	85	0.00
3	305	312	3.00	314	2.95	200	214	7.00	226	13.00	85	86	1.18	85	0.00
4	285	297	4.21	285	0.00	169	186	10.06	169	0.00	78	81	3.85	84	7.69
5	310	312	0.65	317	2.26	225	233	3.56	229	1.78	85	85	0.00	86	1.18
6	295	299	1.36	295	0.00	215	220	2.33	215	0.00	82	82	0.00	82	0.00
7	310	305	1.61	310	0.00	235	220	-6.38	222	-5.53	84	84	0.00	84	0.00
8	300	298	0.67	300	0.00	215	204	-5.12	215	0.00	85	83	-2.35	85	0.00
9	305	300	1.64	305	0.00	220	225	2.27	220	0.00	83	82	-1.20	83	0.00
10	290	301	3.79	290	0.00	295	282	-4.41	231	-21.69	82	84	2.44	82	0.00
11	285	293	2.81	300	5.26	205	207	0.98	219	6.83	79	81	2.53	82	3.80
12	290	283	2.41	290	0.00	220	230	4.55	223	1.36	82	80	-2.44	82	0.00
13	345	345	0.00	345	0.00	245	245	0.00	245	0.00	97	97	0.00	97	0.00
14	345	350	2.90	345	0.00	235	245	4.26	238	1.28	97	94	-3.09	97	0.00
15	350	338	3.43	350	0.00	220	224	1.82	231	5.00	96	101	5.21	96	0.00
16	370	363	1.89	370	0.00	220	211	-4.09	220	0.00	102	93	-8.82	102	0.00
17	330	338	2.42	328	-0.61	230	242	5.22	230	0.00	91	92	1.10	91	0.00
18	335	330	1.49	330	-1.49	230	240	4.35	225	-2.17	93	91	-2.15	93	0.00
19	325	334	2.77	325	0.00	230	230	0.00	230	0.00	91	93	2.20	91	0.00
20	325	310	4.62	325	0.00	220	222	0.91	222	0.91	90	87	-3.33	89	-1.11
21	345	336	2.61	345	0.00	260	241	-7.31	260	0.00	94	92	-2.13	94	0.00
22	345	336	2.61	340	-1.45	255	239	-6.27	243	-4.71	93	93	0.00	93	0.00
23	340	333	2.06	340	0.00	235	222	-5.53	233	-0.85	95	92	-3.16	95	0.00
24	345	346	0.29	345	0.00	220	210	-4.55	220	0.00	97	96	-1.03	95	-2.06
25	310	315	1.61	320	3.23	225	231	2.67	231	2.67	85	87	2.35	85	0.00
26	300	296	1.33	300	0.00	220	228	3.64	220	0.00	82	83	1.22	83	1.22

表 3 PLS、BPNN、PLS-BPNN 和 SVR 的 LOOCV 预测性能比较

Table 3 Comparison of prediction performances among PLS, BPNN, PLS-BPNN and SVR using LOOCV

Method	$\sigma_b$ /MPa			$\sigma_{0.2}$ /MPa			HB		
	RMSE	MRE/%	R <sup>2</sup>	RMSE	MRE/%	R <sup>2</sup>	RMSE	MRE/%	R <sup>2</sup>
PLS <sup>[1]</sup>	12.163 5	2.993 0	-	23.987 7	7.300 2	-	3.453 0	2.917 8	-
BPNN <sup>[1]</sup>	9.674 5	2.297 8	-	19.008 2	5.058 9	-	2.759 8	2.453 9	-
PLS-BPNN <sup>[1]</sup>	8.922 3	2.142 1	0.903 8	15.499 7	4.436 5	0.788 1	2.168 4	1.890 4	0.833 5
SVR-LOOCV	4.531 9	0.722 5	0.964 8	14.550 8	2.607 0	0.563 7	1.414 2	0.656 1	0.958 8

其泛化性能最强。此外,除了  $\sigma_{0.2}$  预测结果的相关系数(0.563 7)比 PLS-BPNN 的 0.788 1 小之外,其它两种

力学性能的相关系数(0.964 8, 0.958 8)均比 PLS-BPNN (0.903 8, 0.833 5)的大。

以上结果表明 SVR 模型的预测能力比 PLS、BPNN 和 PLS-BPNN 的要强。

## 4 结论

1) SVR-LOOCV 的预测性能最优, 其预测的均方根误差和平均相对误差均为最小。

2) SVR 是一种预测 7005 铝合金力学性能的有效方法, 该方法为更加准确地预测不同工艺参数下铝合金的力学性能提供了一种新的有效途径。

3) 在研制各种高性能合金材料时, SVR 只需通过少量的实验数据进行建模, 可为相关实验提供工艺参数的理论优化设计。

## REFERENCES

- [1] 方善锋, 汪明朴, 王正安, 齐卫宏, 李 周. PLS-BPN 法用于 7005 铝合金力学性能与工艺参数的定量研究[J]. 中国有色金属学报, 2007, 17(12): 1948-1954.  
FANG Shan-feng, WANG Ming-pu, WANG Zheng-an, QI Wei-hong, LI Zhou. Quantitative study between mechanical properties and processing parameters for 7005Al alloys predicted using PLS-BPN method[J]. The Chinese Journal of Nonferrous Metals, 2007, 17(12): 1948-1954.
- [2] VAPNIK V. The nature of statistical learning theory[M]. New York: Springer, 1995.
- [3] HUANG C, DAVIS L S, TOWNSHEND J R G. An assessment of support vector machines for land cover classification[J]. International Journal of Remote Sensing, 2002, 23(4): 725-749.
- [4] KIM K I, JUNG K, PARK S H, KIM H J. Support vector machine-based text detection in digital video[J]. Pattern Recognition, 2001, 34(2), 527-529.
- [5] THUBTHONG N, KIJSIRIKUL B. Support vector machines for Thai phoneme recognition[J]. International Journal of Uncertainty Fuzziness and Knowledge-Based Systems, 2001, 9(6): 803-813.
- [6] TAY F E H, CAO L J. Epsilon-descending support vector machines for financial time series forecasting[J]. Neural Processing Letters, 2002, 15(2): 179-195.
- [7] LIONG S Y, SIVAPRAGASAM C. Flood stage forecasting with support vector machines[J]. Journal of the American Water Resources Association, 2002, 38(1): 173-186.
- [8] GAVRISHCHAKA V V, GANGULI S B. Support vector machines as an efficient tool for high-dimensional data processing: Application to sub-storm forecasting[J]. Journal of Geophysical Research-Space Physics, 2001, 106(A12): 29911-29914.
- [9] BURBIDGE R, TROTTER M, BUXTON B, HOLDEN S. Drug design by machine learning: Support vector machines for pharmaceutical data analysis[J]. Computers and Chemistry, 2001, 26(1): 5-14.
- [10] CAI C Z, HAN L Y, JI Z L, CHEN Y Z. Enzyme family classification by support vector machines[J]. Proteins, 2004, 55(1): 66-76.
- [11] HUA S J, SUN Z R. A novel method of protein secondary structure prediction with high segment overlap measure: support vector machine approach[J]. Journal of Molecular Biology, 2001, 308(2): 397-407.
- [12] CAI C Z, HAN L Y, JI Z L, CHEN X, CHEN Y Z. SVM-Prot: Web based support vector machine software for functional classification of a protein from its primary sequence[J]. Nucleic Acids Research, 2003, 31(13): 3692-3697.
- [13] WEN Y F, CAI C Z, LIU X H, PEI J F, ZHU X J, XIAO T T. Corrosion rate prediction of 3C steel under different seawater environment based on support vector regression[J]. Corrosion Science, 2009, 51(2): 349-355.
- [14] 温玉锋, 蔡丛中, 裴军芳, 朱星键, 肖婷婷. R<sub>2</sub>O-MO-Al<sub>2</sub>O<sub>3</sub>-SiO<sub>2</sub> 玻璃配方与热膨胀系数关系的支持向量回归研究[J]. 功能材料, 2009, 40(1): 66-70.  
WEN Yu-feng, CAI Cong-zhong, PEI Jun-fang, ZHU Xing-jian, XIAO Ting-ting. Study on the relationship between thermal expansion coefficient and oxide composition of R<sub>2</sub>O-MO-Al<sub>2</sub>O<sub>3</sub>-SiO<sub>2</sub> system glass via support vector regression approach[J]. Journal of Functional Materials, 2009, 40(1): 66-70.
- [15] KENNEDY J, EBERHART R. Particle swarm optimization[C]// Proc IEEE Int Conf Neural Networks, 1995: 1942-1948.
- [16] YANG Y, CHEN S, YE Z B. Combination of particle-swarm optimization with least-squares support vector machine for FDTD time series forecasting[J]. Microwave and Optical Technology Letters, 2006, 48(1): 141-144.

(编辑 何学锋)