

# AION-TiN 复相材料合成工艺参数的 支持向量回归分析\*

温玉锋 蔡从中<sup>†</sup> 裴军芳 朱星键 肖婷婷 王桂莲

( 重庆大学应用物理系, 重庆 400044 )

( 2009 年 1 月 15 日收到, 2009 年 4 月 20 日收到修改稿 )

根据在不同热压烧结工艺参数(包括 TiN 的含量、烧结温度和保温时间)下合成的 AION-TiN 复相材料的抗弯强度实测数据集,应用基于粒子群算法寻优的支持向量回归(SVR)方法,建立了 AION-TiN 复相材料在不同热压烧结工艺参数下抗弯强度的 SVR 预测模型,并与基于人工神经网络(ANN)模型的预测结果进行了比较.利用 SVR 预测模型并结合粒子群算法对 AION-TiN 合成工艺参数进行了寻优和多因素分析.结果显示:对于相同的训练样本和检验样本,AION-TiN 复相材料抗弯强度的 SVR 模型比 ANN 模型具有更小的预测误差,表明 SVR 模型比 ANN 模型具有更强的预测能力.工艺参数寻优结果表明,当 TiN 质量分数为 13.5%、烧结温度为 1863.5 °C 和保温时间为 5.8 h 时,可获得抗弯强度为 555.452 MPa 的 AION-TiN 复相材料.研究结果表明,该方法对于研发理想抗弯强度的 AION-TiN 复相材料具有重要的理论指导意义和实用价值.

关键词: AION-TiN, 抗弯强度, 支持向量回归, 回归分析

PACC: 0270, 0650

## 1. 引 言

氮氧化铝尖晶石(AION)是 AlN 和 Al<sub>2</sub>O<sub>3</sub> 的固溶体. AION 具有优良的力学、光学和化学等性能,但在某一温度以下其热力学不稳定性会导致其力学性能降低,在一定程度上限制了其应用.近几十年来,为了提高 AION 的力学性能和化学性能,国内外许多学者开展了向 AION 中引入第二相制备 AION 为主晶相的复相材料研究,并取得了良好的效果<sup>[1-7]</sup>. TiN 是共价键化合物,具有高硬度、高熔点和良好的导电性能.尽管 TiN 难以烧结,但是仍有许多研究者把 TiN 作为第二相引入到 AION 复相材料中,利用其高硬度、高熔点和良好的导电性能来提高 AION 的性能. AION-TiN 复相材料的性能不仅取决于其预先设计的化学组成,而且添加剂的选择以及材料的制备过程中工艺参数的选择(如烧结的气氛、温度、压力等)也会对其性能产生很大影响.由于 AION-TiN

复合材料的原始组成复杂,且 TiN 难以烧结,因而为制备出性能良好的 AION-TiN 复相材料寻找合适的工艺参数及配方显得尤为必要.

随着人工智能技术的不断发展,计算机辅助设计在材料科学领域也得到了不断的发展,除传统多元线性回归方法<sup>[8,9]</sup>外,人工智能方法(如神经网络<sup>[10-13]</sup>、遗传算法<sup>[14-16]</sup>等)已被广泛地应用于材料工艺的设计和优化.支持向量机是由 Vapnik<sup>[17]</sup>于 1995 年提出的一种基于结构风险最小化的统计学习方法,可用于分类和回归分析,已被成功地应用于很多领域<sup>[18-28]</sup>.本文利用文献[10]所报道的热压合成 AION-TiN 复合材料的实测数据集,应用支持向量回归(support vector regression,简记为 SVR)方法,并结合粒子群参数寻优(particle swarm optimization,简记为 PSO)算法,对不同热压工艺参数下合成的 AION-TiN 复合材料抗弯强度进行了建模预测和工艺优化,同时对寻优结果进行了多因素分析.

\* 教育部新世纪优秀人才支持计划(批准号: NCET-07-0903)、教育部留学回国人员科研启动基金(批准号: 2008101-1)、重庆市自然科学基金(批准号: CSTC2006BS240)和国家大学生创新性实验计划(批准号: XQUCX-G-2007-016)资助的课题.

<sup>†</sup> 通讯联系人. E-mail: caiczhang@gmail.com

## 2. 原理与方法

### 2.1. SVR 原理

设样本集为  $(x_1, y_1), \dots, (x_m, y_m)$ , 寻找一个非线性映射  $\Phi$  将样本集中的数据  $x$  映射到高维空间  $F$  并在特征空间  $F$  中进行线性回归,

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

式中  $b$  是阈值,  $w$  是回归系数向量. 在映射  $\Phi$  选定后, 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

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

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

式中  $m$  是样本数,  $L_\epsilon(f(x_i) - y_i)$  是损失函数,  $C$  是惩罚因子,  $\epsilon$  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的回归误差, 引入松弛因子  $\xi$  和  $\xi^*$ , 以处理不满足 (3) 式的数据点. SVR 方法是通过最小化目标函数  $R(w, \xi_i, \xi_i^*)$  来确定 (1) 式中的  $w$  和  $b$ ,

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

且满足

$$\begin{aligned} y_i - w \cdot x_i - b &\leq \epsilon + \xi_i, \\ w \cdot x_i + b - y_i &\leq \epsilon + \xi_i^*, \\ \xi_i &\geq 0, \\ \xi_i^* &\geq 0. \end{aligned}$$

(4) 式等号右端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  $\epsilon$  的样本的惩罚程度. 为求解  $w$  和  $b$ , 建立如下拉格朗日方程:

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

$$\begin{aligned} &+ y_i + (w \cdot \Phi(x_i)) - b) \\ &\quad - \sum_{i=1}^m (\lambda_i \xi_i + \lambda_i^* \xi_i^*). \end{aligned} \quad (5)$$

要使 (5) 式取得最小值,  $L$  对于参数  $w, b, \xi_i, \xi_i^*$  的偏导数都应等于零. 由 (5) 式可以得到下列对偶优化问题:

$$\begin{aligned} \min \left\{ \frac{1}{2} \sum_{i,j=1}^m (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) (\Phi(x_i) \cdot \Phi(x_j)) \right. \\ \left. + \sum_{i=1}^m \alpha_i (\epsilon - y_i) + \sum_{i=1}^m \alpha_i^* (\epsilon + y_i) \right\} = Q, \quad (6) \end{aligned}$$

且满足

$$\begin{aligned} \sum_{i=1}^m (\alpha_i - \alpha_i^*) &= 0, \\ \alpha_i &\in [0, C], \\ \alpha_i^* &\in [0, C]. \end{aligned}$$

通过求解二次规划 (6) 式, 可以得到用训练样本点和拉格朗日乘子表示的  $w$ , 即

$$w = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \Phi(x_i), \quad (7)$$

式中  $\alpha_i$  和  $\alpha_i^*$  是最小化目标函数  $R(w, \xi_i, \xi_i^*)$  的解. 由此可求得线性回归函数

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) k(x, x_i) + b, \quad (8)$$

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 模型. 常用的核函数有径向基函数、多项式函数、sigmoid 函数、线性函数等. 本文采用径向基函数建立 SVR 模型.

### 2.2. SVR 参数的 PSO 算法寻优

由于 SVR 模型的泛化性能完全依赖于误差  $\epsilon$ 、惩罚因子  $C$  和核函数参数  $\gamma$ , 因而进行  $\epsilon, C, \gamma$  参数寻优对于 SVR 模型达到最优泛化性能十分关键. 采用 PSO 算法<sup>[29]</sup>来寻找参数  $\epsilon, C, \gamma$  的最优值. 群体中的每个粒子由三维参数向量  $(\epsilon, C, \gamma)$  组成. 设第  $i$  个粒子在三维解空间的位置为  $u_i = (u_{i1}, u_{i2}, u_{i3})^T$ , 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、全局极值及其自身前一刻的状态来调整当前时刻的位置和速度, 其迭代公式为<sup>[30]</sup>

$$\begin{aligned} v_i(t+1) &= \omega v_i(t) + c_1 \text{rand}() \cdot (p_{ibest} - u_i(t)) \\ &\quad + c_2 \text{rand}() \cdot (g_{best} - u_i(t)), \quad (9) \end{aligned}$$

$$u_i(t+1) = u_i(t) + v_i(t+1). \quad (10)$$

这里,  $v(t)$  和  $v(t+1)$  分别是粒子在当前时刻和下一时刻的速度,  $u(t)$  和  $u(t+1)$  分别是粒子在当前时刻和下一时刻的位置;  $\text{rand}(\cdot)$  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,  $\omega$  应随算法迭代的进行而自动调节.  $\omega$  一般定义为

$$\omega = \omega_{\min} + (N_{\max} - N) (\omega_{\max} - \omega_{\min}) / N_{\max} \quad (11)$$

式中,  $\omega_{\max}$ ,  $\omega_{\min}$  分别为最大、最小权重因子, 且  $\omega_{\max}$  和  $\omega_{\min}$  的值一般取为 0.9 和 0.4;  $N$  为当前迭代次数;  $N_{\max}$  为总的迭代次数. 为了直接反映 SVR 模型的回归性能, 选用均方根误差  $E_{\text{RMS}}$  作为适应度函数,

$$E_{\text{RMS}} = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2}, \quad (12)$$

式中,  $m$  是训练样本数,  $y_i$  是第  $i$  个训练样本目标量的实测值,  $\hat{y}_i$  是第  $i$  个训练样本目标量的预测值.

### 3. SVR 模型的建立

#### 3.1. 热压合成 AION-TiN 复相材料的实验数据集

本文所用数据集源自文献 [10]. 该数据集总共包含 18 个样本 (见表 1), 是张作泰等 [10] 采用热压法合成 AION-TiN 复相材料的实验数据. 他们选取 2 个样本 (编号为 4 和 15) 作为检验样本, 其余 16 个样本为训练样本进行了人工神经网络 (ANN) 建模研究. 热压合成 AION-TiN 的详细实验过程可参见文献

表 1 热压合成 AION-TiN 复相材料的实验数据 [10]

样本编号	$w/\%$	$T/^\circ\text{C}$	$t/\text{h}$	$S_b/\text{MPa}$
1	13	1800	3	424.26
2	15	1800	3	483.20
3	3	1800	4	335.60
4	5	1800	4	407.70
5	10	1800	2	364.30
6	8	1800	2	376.61
7	2	1750	5	381.32
8	3	1750	2	316.84
9	15	1750	3	441.97
10	13	1750	3	416.95
11	8	1750	4	383.50
12	10	1750	4	386.18
13	5	1850	4	341.08
14	3	1850	4	286.62
15	15	1850	3	487.71
16	13	1850	3	447.90
17	8	1850	2	372.56
18	10	1850	2	406.47

[10]. 文献 [10] 的作者还分别使用正交实验和遗传算法对工艺参数进行了寻优. 其正交实验最优工艺条件为 TiN 质量分数  $w = 15\%$ , 烧结温度  $T = 1800^\circ\text{C}$ , 保温时间  $t = 2\text{ h}$ , 抗弯强度  $S_b = 483.20\text{ MPa}$ . 遗传算法寻优确定的最佳工艺参数为 TiN 的质量分数  $w = 15\%$ ,  $T = 1830^\circ\text{C}$ ,  $t = 2.45\text{ h}$ ,  $S_b = 489.4\text{ MPa}$ .

#### 3.2. 模型的建立

在利用 SVR 方法的训练建模过程中, 以热压烧结工艺参数中 TiN 的质量分数  $w$ 、烧结温度  $T$  和保温时间  $t$  等三个参数为输入变量, 以 AION-TiN 复相材料的抗弯强度  $S_b$  为输出进行训练学习. 为了便于与文献 [10] 中的 ANN 模型的预测结果进行直接比较, 按照与文献 [10] 完全相同的训练样本和检验样本进行 SVR 模型训练和预测. 此外, 在已建立的 SVR 模型基础上, 利用 PSO 算法对工艺参数进行寻优以及多因素分析.

#### 3.3. 模型预测性能的评价

除  $E_{\text{RMS}}$  外, 还采用平均绝对误差  $E_{\text{mean A}}$ 、平均相对误差绝对值  $E_{\text{mean AP}}$  以及相关系数  $r^2$  对所建模型的预测性能进行评价. 它们分别由下列公式定义:

$$E_{\text{mean A}} = \frac{1}{n} \sum_{j=1}^n |\hat{y}_j - y_j|, \quad (13)$$

$$E_{\text{mean AP}} = \frac{1}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right|, \quad (14)$$

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

在 (13)–(15) 式中,  $n$  是检验样本数,  $y_j$  和  $\hat{y}_j$  分别是第  $j$  个检验样本目标值和预测值,  $\bar{y}$  是检验样本目标值的平均值.

## 4. 结果分析与讨论

#### 4.1. 预测结果对比

图 1 给出了 16 个训练样本抗弯强度的 SVR 模型预测值和实测值之间的比较. 表 2 列出了 2 个检验样本抗弯强度实测值与 ANN 模型和 SVR 模型的预测结果及相对误差. 表 3 列出了利用 ANN 模型和 SVR 模型得到的对检验样本抗弯强度的预测性能值.

从图 1 可以看出,除极个别样本点外,SVR 模型拟合值与实测值符合很好,SVR 模型预测的相关系数( $r^2 = 0.9958$ )大于文献 [10] 所报道的 ANN 模型预测的相关系数( $r^2 = 0.9865$ ).在表 2 中,2 个检验样本的 SVR 模型预测结果的误差分别为 0.19% 和 0.08%,比用 ANN 模型得到的误差 2.70% 和 1.96% 要小.由此可知,无论是训练样本还是检验样本,SVR 模型的预测结果更接近于实验值,表明 SVR 模型的预测精度高于用 ANN 模型得到的预测精度,SVR 模型比 ANN 模型具有更强的泛化能力.从表 3 可以看到,检验样本的 SVR 模型预测结果的  $E_{\text{RMS}} = 0.59 \text{ MPa}$ ,  $E_{\text{mean A}} = 0.57 \text{ MPa}$  和  $E_{\text{mean AP}} = 0.14\%$ ,均比 ANN 模型预测的相应误差要小.这也表明 SVR 模型的预测精度要比 ANN 模型的预测精度高,泛化能

力比 ANN 模型更强.




图 1 训练样本的 SVR 模型预测值与抗弯强度实测值的比较

表 2 检验样本的 ANN 模型和 SVR 模型对抗弯强度  $S_b$  的预测值及误差

样本编号	$w/\%$	$T/^\circ\text{C}$	$t/\text{h}$	实测值/MPa	ANN 模型预测值 <sup>[10]</sup> /MPa	ANN 模型预测误差/%	SVR 模型预测值/MPa	SVR 模型预测误差/%
4	5	1800	4	364.30	354.48	-2.70	363.56	-0.19
15	15	1850	3	487.71	478.13	-1.96	488.11	-0.08

表 3 ANN 模型和 SVR 模型对检验样本预测结果的性能比较

回归方法	$E_{\text{RMS}}/\text{MPa}$	$E_{\text{mean A}}/\text{MPa}$	$E_{\text{mean AP}}/\%$
ANN <sup>[10]</sup>	9.70	9.70	2.33
SVR	0.59	0.57	0.14

## 4.2. PSO 算法寻优

在已训练好的 SVR 模型基础上,以获取最大抗弯强度  $S_b$  为目标,TiN 的质量分数  $w$ 、烧结温度  $T$  和保温时间  $t$  的步长分别取为 0.5%,10.0  $^\circ\text{C}$  和 0.1 h,种群大小为 20,利用 PSO 算法对工艺参数  $w$ ,  $T$  和  $t$  进行寻优,得到的最佳工艺参数分别为  $w = 13.5\%$ ,  $T = 1863.5 \text{ }^\circ\text{C}$  和  $t = 5.8 \text{ h}$ ,所对应的  $S_b = 555.452 \text{ MPa}$ .

## 4.3. 多因素分析

图 2、图 3 和图 4 分别给出了在某一最佳工艺参数不变,另外两个工艺参数改变时由 SVR 预测的 AlON-TiN 抗弯强度值.

图 2 所示为 TiN 的含量  $w = 13.5\%$  时抗弯强度  $S_b$  随烧结温度  $T$  和保温时间  $t$  的变化.从图 2 可以看出,当 TiN 含量  $w$  一定时,抗弯强度随烧结温度的升高先增加后减小,随保温时间的增加先减小后

增大.




图 2 SVR 模型预测 AlON-TiN 抗弯强度随烧结温度和保温时间的变化  $w = 13.5\%$

图 3 所示为烧结温度  $T = 1863.5 \text{ }^\circ\text{C}$  时抗弯强度  $S_b$  随 TiN 含量  $w$  和保温时间  $t$  的变化.从图 3 可以看出,当烧结温度  $T$  一定时,抗弯强度随 TiN 含量的增加而增大,随保温时间的增加先减小后增大.

图 4 所示为保温时间  $t = 5.8 \text{ h}$  时抗弯强度  $S_b$  随烧结温度  $T$  和 TiN 含量  $w$  的变化.从图 4 可以看出,当保温时间一定时,抗弯强度随 TiN 含




图3 SVR模型预测 AION-TiN 抗弯强度随 TiN 含量和保温时间的变化  $T = 1863.5\text{ }^{\circ}\text{C}$




图4 SVR模型预测 AION-TiN 抗弯强度随 TiN 含量和烧结温度的变化  $t = 5.8\text{ h}$

量的增加而增大,而随烧结温度的升高先增加后减小。

## 5. 结 论

根据不同热压烧结工艺参数下合成的 AION-TiN 复相材料的抗弯强度实测数据集,应用基于 PSO 算法寻优的 SVR 方法,建立了 AION-TiN 复相材料在不同热压烧结工艺参数下的抗弯强度的 SVR 预测模型,并与基于 ANN 模型的预测结果进行了比较。结果表明,在相同的训练与测试样本集下,SVR 模型具有更小的预测误差、更高的预测精度和更强的泛化能力。利用 PSO 对工艺参数进行多因素分析的结果显示:当 TiN 含量一定时,抗弯强度随烧结温度的升高先增加后减小,随保温时间的增加先减小后增大;当烧结温度一定时,抗弯强度随 TiN 含量的增加而增大,随保温时间的增加先减小后增大;当保温时间一定时,抗弯强度随 TiN 含量的增加而增大,随烧结温度的升高先增加后减小。该方法对于寻找和研发理想抗弯强度的 AION-TiN 复相材料具有重要的理论指导意义和实用价值。

[1] Yamashita H, Yamaguchi A 2003 *Refractories* **37** 194 (in Chinese) [山下敬、山口明良 2003 *耐火材料* **37** 194]

[2] Djenkal D, Goeruiot D, Thevenot F 2000 *J. Eur. Ceram. Soc.* **20** 2585

[3] Berriche Y, Vallayer J, Trabelsi R, Treheux D 2000 *J. Eur. Ceram. Soc.* **20** 1311

[4] Yamashita H, Yamaguchi A 2001 *J. Ceram. Soc. Jpn.* **109** 434

[5] Mandal S, Sanyal A S, Dhargupta K K, Ghatak S 2001 *Ceram. Int.* **27** 473

[6] Zhang Z T, Saiyin B, Li W C 2004 *J. Mater. Sci. Eng.* **22** 5 (in Chinese) [张作泰、赛音巴特尔、李文超 2004 *材料科学与工程学报* **22** 5]

[7] Saiyin B, Zhang Z T, Li W C 2004 *Chin. J. Rare Met.* **28** 297 (in Chinese) [赛音巴特尔、张作泰、李文超 2004 *稀有金属* **28** 297]

[8] Timofei S, Kurunzi L, Suzuki T, Fabian W M F, Muresan S 1997 *Dye. Pigment.* **34** 181

[9] Riahi S, Ganjali M R, Pourbasheer E, Norouzi P 2008 *Chromatographia* **67** 917

[10] Zhang Z T, Saiyin B, Li W C 2003 *J. Chin. Ceram. Soc.* **31** 727 (in Chinese) [张作泰、赛音巴特尔、李文超 2003 *硅酸盐学报* **31** 727]

[11] Guo H J, Liu J H 2004 *Acta Phys. Sin.* **53** 4080 (in Chinese) [郭会军、刘君华 2004 *物理学报* **53** 4080]

[12] He G G, Zhu P, Chen H P, Cao Z T 2006 *Acta Phys. Sin.* **55** 1040 (in Chinese) [何国光、朱萍、陈宏平、曹志彤 2006 *物理学报* **55** 1040]

[13] Han M, Shi Z W, Guo W 2007 *Acta Phys. Sin.* **56** 43 (in Chinese) [韩敏、史志伟、郭伟 2007 *物理学报* **56** 43]

[14] Chen C L, Vempati V S, Aljaber N 1995 *Eur. J. Oper. Res.* **80** 389

[15] Kazarlis S A, Bakirtzis A G, Petridis V 1996 *IEEE Trans. Power Syst.* **11** 83

[16] Andre N, Cho H W, Baek S H, Jeong M K, Young T M 2008 *Wood Sci. Technol.* **42** 521

[17] Vapnik V 1995 *The Nature of Statistical Learning Theory* (New York: Springer)

[18] Cai C Z, Han L Y, Ji Z L, Chen X, Chen Y Z 2003 *Nucl. Acids Res.* **31** 3692

- [ 19 ] Cai C Z , Wang W L , Sun L Z , Chen Y Z 2003 *Math . Biosci .* **185** 111
- [ 20 ] Cai C Z , Wang W L , Chen Y Z 2003 *Int . J . Mod . Phys . C* **14** 575
- [ 21 ] Yang H Q , Chan L W , King I 2002 *Lect . Note . Comput . Sci .* **2412** 391
- [ 22 ] Cai C Z , Han L Y , Ji Z L , Chen Y Z 2004 *Proteins* **55** 66
- [ 23 ] Wen Y F , Cai C Z , Liu X H , Pei J F , Zhu X J , Xiao T T 2009 *Corros . Sci .* **51** 349
- [ 24 ] Na M G , Kim J W , Lim D H , Kang Y J 2008 *Nucl . Eng . Des .* **238** 1503
- [ 25 ] Wang X Y , Cui C Y 2008 *J . Vis . Commun . Image Represent .* **19** 334
- [ 26 ] Sim H J , Park S G , Joe Y G , Oh J E 2008 *J . Mech . Sci . Technol .* **22** 1121
- [ 27 ] Cui W Z , Zhu C C , Bao W X , Liu J H 2004 *Acta Phys . Sin .* **53** 3303 (in Chinese)[ 崔万照、朱长纯、保文星、刘君华 2004 物理学报 **53** 3303 ]
- [ 28 ] Wang G L , Yang P C , Mao Y Q 2008 *Acta Phys . Sin .* **57** 714 (in Chinese)[ 王革丽、杨培才、毛宇清 2008 物理学报 **57** 714 ]
- [ 29 ] Yang Y , Chen S , Ye Z B 2006 *Microwave Opt . Technol . Lett .* **48** 141
- [ 30 ] Kennedy J , Eberhart R 1995 *Proc . IEEE Int . Conf . Neural Networks* **4** 1942

## Study on the influence of process parameters on the synthesis of AION-TiN composites by using support vector regression \*

Wen Yu-Feng Cai Cong-Zhong<sup>†</sup> Pei Jun-Fang Zhu Xing-Jian Xiao Ting-Ting Wang Gui-Lian

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

( Received 15 January 2009 ; revised manuscript received 20 April 2009 )

### Abstract

According to the experimental dataset on the bending strength of AION-TiN composite synthesized by hot pressing sintering approach under different processing parameters , i. e. , mass fraction of TiN , sintering temperature and soaking time , the support vector regression ( SVR ) approach combined with particle swarm optimization for its parameter optimization , is proposed to simulate the relationship between the bending strength and hot pressing sintering synthesis parameters of AION-TiN composites . The optimization of process parameters and the multi-factor analysis are also carried out . The prediction result demonstrates that the estimation error of the SVR model is less than that of the artificial neural network( ANN ) model under the identical training and test samples and reveals that the generalization ability of SVR model surpasses that achieved by the ANN model . The optimal synthesis parameters are obtained numerically under TiN content 13.5% , sintering temperature 1863.5 °C and soaking time 5.8 h . The maximum bending strength is estimated to be 555.452 MPa while the AION-TiN composite is synthesized at the optimal synthesis parameters . These results suggest that SVR can provide an important theoretical and practical guidance to the research and development of AION-TiN composite possessing ideal bending strength .

**Keywords :** AION-TiN , bending strength , support vector regression , regression analysis

**PACC :** 0270 , 0650

\* Project supported by the Program for the New Century Excellent Talents in University of Ministry of Education , China ( Grant No. NCET-07-0903 ) , the Scientific Research Foundation for the Returned Overseas Chinese Scholars of Ministry of Education , China ( Grant No. 2008101-1 ) , the Natural Science Foundation of Chongqing , China ( Grant No. CSTC2006BB5240 ) and the National Innovation Experimental Program for Undergraduate Students in China ( Grant No. CQUCX-G-2007-016 ).

<sup>†</sup> Corresponding author. E-mail : caicz@gmail.com