

选择性激光烧结成型件密度的 支持向量回归预测^{*}

蔡从中[†] 裴军芳 温玉锋 朱星键 肖婷婷

(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)

根据不同工艺参数(层厚、扫描间距、激光功率、扫描速度、加工环境温度、层与层之间的加工时间间隔和扫描方式)下的选择性激光烧结成型件密度的实测数据集,应用基于粒子群算法寻优的支持向量回归(SVR)方法,建立了加工工艺参数与成型件密度间的预测模型,并与 BP 神经网络模型进行了比较.结果表明:基于相同的训练样本和检验样本,成型件密度的 SVR 模型比其 BP 神经网络模型具有更强的内部拟合能力和更高的预测精度,增加训练样本数有助于提高 SVR 预测模型的泛化能力;基于留一交叉验证法的 SVR 模型的预测误差最小.因此,SVR 是一种预测选择性激光烧结成型件密度的有效方法.

关键词:选择性激光烧结,密度,支持向量机,回归分析

PACC:0270,0650

1. 引 言

选择性激光烧结(selective laser sintering, 简记为 SLS)最初是由美国德克萨斯大学奥斯汀分校的 Deckard 于 1986 年提出^[1],现在已经发展成一种典型的商业化快速成型方法. SLS 工艺过程是以金属、陶瓷、尼龙、ABS 塑料等材料的粉末作为成型材料,利用滚筒层层铺粉,激光器发出的高能光束在计算机的控制下对每层材料粉末进行扫描,使之熔化烧结成型,当一层粉末烧结完成后滚筒上升一层,在烧结层洒上新的一层粉末供下次烧结,直至完成零件的成型.该快速成型技术具有成型速度快、精度高、材料选择面大、用途广,且成型过程无需支撑^[2,3]等特点,已被广泛应用于工业造型、机械制造、航空航天、军事、建筑、影视、家电、轻工、医学、考古、工艺美术等领域. SLS 加工过程是一个物理、化学变化过程,其加工工艺参数与成型件密度间关系极其复杂且呈非线性.因此,在 SLS 成型中,通过建立工艺参数与其密度关系的预测模型,对于准确估计成型件

密度具有十分重要的指导意义.由于神经网络是一种处理复杂非线性关系的强有力工具,因而在材料科学研究领域中得到了广泛的应用和普遍重视^[4-7].到目前为止,已有人利用 BP 神经网络(BPNN)^[8,9]或 BPNN 结合有限元方法^[10]建立了 SLS 成型件密度预测模型.尽管 BPNN 模型能很好地预测成型件密度,但它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.

支持向量机是由 Vapnik^[11]于 1995 年提出的一种基于统计学习理论的监督学习机,可用于多类别分类和回归分析,已被成功地应用到很多实际领域^[12-19].本文利用文献[8]中不同工艺参数下 SLS 成型件密度的实验数据集,应用基于粒子群参数寻优(particle swarm optimization, 简记为 PSO)算法的支持向量回归(support vector regression, 简记为 SVR)方法,并结合留一交叉验证(leave-one-out cross validation, 简记为 LOOCV)法,建立不同加工工艺参数下的 SLS 成型件密度预测模型,并与 BPNN 模型的预测误差进行对比.

^{*} 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:JCSTC2006BB5240)和国家大学生创新性实验计划(批准号:JCQUCX-G-2007-016)资助的课题.

[†] E-mail: caiczhang@gmail.com

2. SVR 方法简介

2.1. 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 Φ . 通过映射 Φ 将样本集中的数据 x 映射到高维空间 F , 并在特征空间 F 中进行如下线性回归:

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

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

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

这里 m 是训练样本数, $E(f(x_i) - y_i)$ 是损失函数, C 是惩罚因子.

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 ξ 和 ξ^* , 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 $R(w, \xi, \xi^*)$ 来确定 (1) 式中的 w 和 b ,

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

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 ϵ 的样本的惩罚程度. 为求解 w 和 b , 建立如下拉格朗日方程:

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

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

为使 (5) 式取得最小值, L 对于参数 w, b, ξ, ξ^* 的偏导数都应等于零, 由此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

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

SVR 的函数回归问题就可归结为求解二次规划 (6) 式, 从而得到用训练样本点表示的 w , 即

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

式中 α_i 和 α_i^* 是最小化目标函数 $R(w, \xi, \xi^*)$ 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 $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$ 是核函数. 本文采用径向基函数来建立 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 ϵ 、惩罚因子 C 和核函数参数 γ , 因而进行 ϵ, C, γ 参数寻优对于 SVR 模型达到最优泛化性能尤其关键. 采用 PSO 算法来寻找参数 ϵ, C, γ 的最优值. 群体中的每个粒子由三维参数向量 (ϵ, C, γ) 组成. 设第 i 个粒子在三维解空间的位置为 $u_i = (u_{i1}, u_{i2}, u_{i3})^T$, 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、全局极值及其自身前一刻的状态来调整当前时刻的位置和速度, 迭代公式如下:

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

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

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; ω 是权重因子. 为加快收敛速度, ω 应随算法迭代的进行而自动调节. 通常 ω 定义为

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

式中 ω_{\max} 、 ω_{\min} 分别是最大、最小权重因子, 且 ω_{\max} 和 ω_{\min} 的值一般取为 0.9 和 0.4^[20]; N 是当前迭代次数; N_{\max} 是总的迭代次数. 为了直接反映 SVR 模型的回归性能, 选用均方根误差 E_{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 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^[21].

3. SVR 预测模型的建立

3.1. 数 据

本文所用数据源于文献 [8]. 该数据集共有 32 个实验样本(见表 1), 是王荣吉等^[8]在不同工艺参数下测定的 SLS 成型件密度 ρ . 他们的试验以 HBI 型材料为成型材料, 采用 RPM-III 型快速成型系统, 在相应的取值范围内选择不同的加工参数, 将原料加工成块状试样并测定 ρ 值. 加工时采用两种扫描方式, 第一种为变向扫描, 称为方式 1; 第二种为分组变向扫描, 称为方式 2. 详细试验过程可参见文献 [8].

表 1 SLS 的不同工艺参数及成型件密度^[8]

样本编号	t_1/mm	p/W	$v/\text{mm} \cdot \text{s}^{-1}$	d_s/mm	T_s/s	$T_c/^\circ\text{C}$	扫描方式	$\rho/\text{g} \cdot \text{cm}^{-3}$
1	0.10	8.0	1300	0.08	1	78	1	0.57
2	0.16	8.0	1300	0.14	0	93	2	0.44
3	0.10	12.0	3000	0.08	0	80	2	0.58
4	0.16	12.0	3000	0.14	1	93	1	0.52
5	0.12	11.5	1800	0.10	2	93	2	0.68
6	0.16	11.0	1800	0.14	0	80	1	0.42
7	0.12	20.0	3000	0.10	0	93	1	0.64
8	0.16	20.0	3000	0.14	2	78	2	0.44
9	0.24	20.0	3000	0.14	0	93	2	0.42
10	0.24	20.0	3000	0.10	2	80	1	0.46
11	0.24	10.5	1800	0.14	2	93	1	0.43
12	0.24	10.0	1800	0.10	0	78	2	0.42
13	0.24	15.0	3000	0.08	1	93	2	0.47
14	0.24	9.0	1300	0.14	1	80	2	0.41
15	0.24	8.5	1300	0.08	0	93	1	0.45
16	0.16	15.0	2000	0.12	3	84	2	0.49
17	0.16	15.0	2000	0.15	4	87	1	0.43
18	0.16	15.0	2400	0.12	4	84	1	0.42
19	0.16	15.0	2400	0.15	3	87	2	0.43
20	0.16	18.0	2000	0.12	3	87	1	0.53
21	0.16	18.0	2000	0.15	4	84	2	0.42
22	0.16	18.0	2400	0.12	4	87	2	0.52
23	0.16	18.0	2400	0.15	3	84	1	0.44
24	0.20	18.0	2400	0.15	4	87	1	0.43
25	0.20	18.0	2400	0.12	3	84	2	0.47
26	0.20	18.0	2000	0.15	3	87	2	0.47
27	0.20	18.0	2000	0.12	4	84	1	0.50
28	0.20	15.0	2400	0.15	4	84	2	0.43
29	0.20	15.0	2400	0.12	3	87	1	0.44
30	0.20	15.0	2000	0.15	3	84	1	0.44
31	0.20	15.0	2000	0.12	4	87	2	0.52
32	0.20	12.5	2000	0.10	0	95	1	0.44

3.2. 模型的建立

在利用 SVR 方法对不同工艺参数下的 SLS 成型件 ρ 值的训练建模过程中,以层厚 t_1 、扫描间距 d_s 、激光功率 p 、扫描速度 v 、加工环境温度 T_e 、层与层之间的加工时间间隔 T_s 和扫描方式 F 等 7 个参数为输入变量,以 ρ 为输出进行训练学习.文献 [8] 将表 1 中编号为 1, 6, 7, 19, 21 和 26 共 6 个样本作为检验样本,其余样本作为训练样本.为了与文献 [8] 中的 BPNN 模型的预测结果进行直接比较,本文应用 SVR 模型针对文献 [8] 中完全相同的训练样本和检验样本进行了训练和预测.此外,本文还利用表 1 中的 32 个样本,应用基于 LOOCV 法的 SVR 模型进行了建模训练与预测研究.

3.3. 模型预测性能的评价

采用最大绝对误差 $E_{\max A}$ 、最大相对误差绝对值 $E_{\max AP}$ 、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.它们分别定义如下:

$$E_{\max A} = \max | \hat{y}_j - y_j | \quad (1 \leq j \leq n), \quad (13)$$

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

$$E_{\text{mean A}} = \frac{1}{n} \sum_{j=1}^n | \hat{y}_j - y_j |, \quad (15)$$

$$E_{\text{mean AP}} = \frac{1}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right|, \quad (16)$$

$$r^2 = \frac{\sum_{j=1}^n (\hat{y}_j - \bar{y})^2}{\sum_{j=1}^n (y_j - \bar{y})^2}. \quad (17)$$

在 (13)–(17) 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.

4. 结果分析与讨论

4.1. SVR 与 BPNN 预测性能的比较

表 2 给出了利用 BPNN 和 SVR 方法建立的模型对 26 个训练样本和 6 个检验样本的 ρ 值预测结果及其误差.同时,表 3 给出了 BPNN 模型和 SVR 模型预测结果的性能比较.从表 2 可以看出,不仅 26 个

训练样本的 SVR 模型预测误差都比 BPNN 模型预测误差要小,而且大多数(67%)检验样本的 SVR 模型预测误差也比 BPNN 模型的预测误差要小.从图 1

表 2 实测 ρ 值与 BPNN 模型和 SVR 模型预测值的比较

样本编号	实测值/ $g \cdot cm^{-3}$	BPNN 模型 预测值 ^[8] / $g \cdot cm^{-3}$	BPNN 模型 预测误差/%	SVR 模型 预测值/ $g \cdot cm^{-3}$	SVR 模型 预测误差/%
1	0.57	0.5147	-9.70	0.5700	0.00
2	0.44	0.4525	2.84	0.4406	0.13
3	0.58	0.5923	2.12	0.5796	-0.07
4	0.52	0.5222	0.42	0.5192	-0.15
5	0.68	0.6924	1.82	0.6789	-0.16
6	0.42	0.4871	15.98	0.4748	13.04
7	0.64	0.5683	-11.20	0.5573	-12.92
8	0.44	0.4522	2.77	0.4408	0.18
9	0.42	0.4322	2.90	0.4192	-0.20
10	0.46	0.4719	2.59	0.4611	0.24
11	0.43	0.4323	0.53	0.4293	-0.17
12	0.42	0.4223	0.55	0.4205	0.12
13	0.47	0.4723	0.49	0.4708	0.18
14	0.41	0.4224	3.02	0.4110	0.24
15	0.45	0.4623	2.73	0.4488	-0.27
16	0.49	0.5023	2.51	0.4910	0.20
17	0.43	0.4323	0.53	0.4312	0.28
18	0.42	0.4322	2.90	0.4207	0.17
19	0.43	0.4681	8.86	0.4410	2.56
20	0.53	0.5323	0.43	0.5288	-0.23
21	0.42	0.4319	2.83	0.4621	10.03
22	0.52	0.5223	0.44	0.5187	-0.25
23	0.44	0.4522	2.77	0.4414	0.32
24	0.43	0.4422	2.84	0.4310	0.24
25	0.47	0.4823	2.62	0.4700	-0.01
26	0.47	0.4546	-3.28	0.4621	-1.68
27	0.50	0.5122	2.44	0.4993	-0.14
28	0.43	0.4423	2.86	0.4287	-0.30
29	0.44	0.4522	2.77	0.4412	0.27
30	0.44	0.4422	0.50	0.4387	-0.29
31	0.52	0.5224	0.46	0.5192	-0.16
32	0.44	0.4523	2.80	0.4413	0.29

可直观地看出,绝大多数样本的 SVR 模型预测值比 BPNN 模型预测值更接近实测值.对 32 个样本总体

而言, 93.75% 的样本 SVR 模型预测误差小于 BPNN 模型预测误差. 从表 3 可以看出, SVR 模型对训练样本集预测结果的 $E_{\max A} = 0.0014 \text{ g} \cdot \text{cm}^{-3}$, $E_{\max AP} = 0.32\%$, $E_{\text{mean } A} = 0.0009 \text{ g} \cdot \text{cm}^{-3}$, $E_{\text{mean } AP} = 0.20\%$, 都比 BPNN 模型预测的相应误差要小, 表明 SVR 模型的内部拟合能力比 BPNN 模型要强. 此外, 虽然 SVR 模型对检验样本集的预测结果的 $E_{\max A} = 0.0827 \text{ g} \cdot \text{cm}^{-3}$, 比 BPNN 模型的 $E_{\max A} = 0.0717 \text{ g} \cdot \text{cm}^{-3}$ 稍大, 但 SVR 模型对检验样本集的 $E_{\max AP} = 13.04\%$, $E_{\text{mean } A} = 0.0331 \text{ g} \cdot \text{cm}^{-3}$ 和 $E_{\text{mean } AP} = 6.70\%$ 分别比 BPNN 模型的 $E_{\max AP} = 15.98\%$, $E_{\text{mean } A} = 0.0433 \text{ g} \cdot \text{cm}^{-3}$ 和 $E_{\text{mean } AP} = 8.64\%$ 要小. 由此说明 SVR 模型的预测效果比 BPNN 模型的预测效果要好, 其预测精度比 BPNN 模型更高. 同时, 表 3 还给出了 BPNN 模型和 SVR 模型对训练样本集和检验样本集的预测值与实测值的相关系数 r^2 . 无论是训练集还是测试集, SVR 模型预测值与实测值之间

的相关性均比 BPNN 模型要强. 由此可知, SVR 模型的内部拟合效果和外推效果都比 BPNN 模型要好.




图 1 BPNN 模型^[8]和 SVR 模型的预测值与实测值的比较

表 3 BPNN 模型和 SVR 模型预测结果的性能比较

数据集	回归方法	$E_{\max A}/\text{g} \cdot \text{cm}^{-3}$	$E_{\max AP}/\%$	$E_{\text{mean } A}/\text{g} \cdot \text{cm}^{-3}$	$E_{\text{mean } AP}/\%$	r^2
训练集	BPNN ^[8]	0.0125	3.02	0.0088	1.91	0.9936
	SVR	0.0014	0.32	0.0009	0.20	0.9998
测试集	BPNN ^[8]	0.0717	15.98	0.0433	8.64	0.7960
	SVR	0.0827	13.04	0.0331	6.70	0.8242

4.2. SVR-LOOCV 方法与 BPNN 模型和 SVR 模型预测性能比较

表 4 给出了应用 SVR-LOOCV 方法、BPNN 模型和 SVR 模型对检验样本预测结果的性能对比. 从表 4 可以看出, SVR-LOOCV 方法预测的 $E_{\max A} = 0.0470 \text{ g} \cdot \text{cm}^{-3}$, $E_{\max AP} = 11.19\%$, $E_{\text{mean } A} = 0.0144 \text{ g} \cdot \text{cm}^{-3}$ 和 $E_{\text{mean } AP} = 2.96\%$ 均为最小. 在表 4 中还给出了 SVR-

LOOCV 方法预测结果与实测值之间的相关系数 $r^2 = 0.9010$, 这比 BPNN 模型的 $r^2 = 0.7960$ 和 SVR 模型的 $r^2 = 0.8242$ 都要大. 由此可知, 基于 LOOCV 法的 SVR 模型的预测效果比 BPNN 模型和 SVR 模型的预测效果要好. 从表 4 同时还可以看出, 对于 SVR 模型, 训练样本数越多, 预测效果就越好. 这表明采集更多的实验数据对于提高 SVR 模型的预测准确性有很大的帮助.

表 4 SVR-LOOCV 方法与 BPNN 模型和 SVR 模型的预测性能比较

回归方法	$E_{\max A}/\text{g} \cdot \text{cm}^{-3}$	$E_{\max AP}/\%$	$E_{\text{mean } A}/\text{g} \cdot \text{cm}^{-3}$	$E_{\text{mean } AP}/\%$	r^2
BPNN ^[8]	0.0717	15.98	0.0433	8.64	0.7960
SVR	0.0827	13.04	0.0331	6.70	0.8242
SVR-LOOCV	0.0470	11.19	0.0144	2.96	0.9010

图 2 是经 SVR-LOOCV 方法建模的预测值与实测值的对比. 在 32 个样本中, 预测为零误差的样本共有 17 个, 绝对误差在 $0-0.05 \text{ g} \cdot \text{cm}^{-3}$ 范围内的样

本有 14 个, 只有编号为 7 的 1 个样本的绝对误差超过 $0.05 \text{ g} \cdot \text{cm}^{-3}$. 经统计, 绝大多数 (75%) 样本的相对误差的绝对值小于 5%, 其中有 17 个样本的相对




图2 SVR-LOOCV 法的预测值与实测值的比较

误差为零;此外,相对误差的绝对值超过 10% 的样本共有 2 个,占总样本数的 6.25%。

5. 结 论

根据不同工艺参数下的 SLS 成型件密度实测数据集,应用基于 PSO 参数寻优的 SVR 方法对不同 SLS 加工工艺参数与成型件密度间的关系进行了建模与预测研究,并与基于 BPNN 模型的预测结果进行了比较。研究结果表明:在相同的训练与测试样本集下,与 BPNN 模型相比,SVR 模型不仅具有更强的内部拟合能力,而且对外部测试集的预测结果具有更小的预测误差、更高的预测精度和更强的推广能力。增加训练样本量有助于提高 SVR 预测模型的泛化能力。基于 SVR-LOOCV 方法所获预测结果的 $E_{\max A}$, $E_{\max AP}$, $E_{\text{mean } A}$, $E_{\text{mean } AP}$ 均为最小,预测效果最好。因此,通过增加学习样本量可以进一步提高 SVR 模型的预测精度。同时也说明该方法是一种能够预测不同工艺参数下的 SLS 成型件密度的有效方法。

- [1] Deckard C R 1986 *M. Sc. Thesis* (Austin : University of Texas)
- [2] Caulfield B , McHugh P E , Lohfeld S 2007 *J. Mater. Process. Technol.* **182** 477
- [3] Derby B 2002 *J. Mater. Sci.* **37** 3091
- [4] Reddy N S , Lee Y H , Park C H , Lee C S 2008 *Mater. Sci. Eng. A* **492** 276
- [5] Sha W 2008 *Mater. Sci. Eng. A* **492** 491
- [6] Tsoukalas V D 2008 *Mater. Design* **29** 2027
- [7] Topcu I B , Karakurt C , Saridemir M 2008 *Mater. Design* **29** 1986
- [8] Wang R J , Wang L L , Zhao L H 2005 *J. Hunan Univ. (Nat. Sci. Ed.)* **32** 95 (in Chinese) [王荣吉、王玲玲、赵立华 2005 湖南大学学报(自然科学版) **32** 95]
- [9] Shen X F , Yao J , Wang Y , Yang J L 2004 *Lect. Note. Comput. Sci.* **3174** 832
- [10] Boillat E , Kolossov S , Glardon R , Loher M , Saladin D , Levy G 2004 *Proc. Inst. Mech. Eng. B* **218** 607
- [11] Vapnik V 1995 *The Nature of Statistical Learning Theory* (New York : Springer)
- [12] Cai J W , Hu S S , Tao H F 2007 *Acta Phys. Sin.* **56** 6820 (in Chinese) [蔡俊伟、胡寿松、陶洪峰 2007 物理学报 **56** 6820]
- [13] Ye M Y , Wang X D , Zhang H R 2005 *Acta Phys. Sin.* **54** 2568 (in Chinese) [叶美盈、汪晓东、张浩然 2005 物理学报 **54** 2568]
- [14] Cai C Z , Han L Y , Ji Z L , Chen X , Chen Y Z 2003 *Nucl. Acids Res.* **31** 3692
- [15] Cai C Z , Wang W L , Chen Y Z 2003 *Int. J. Mod. Phys. C* **14** 575
- [16] Cai C Z , Wang W L , Sun L Z , Chen Y Z 2003 *Math. Biosci.* **185** 111
- [17] Song M H , Breneman C M , Bi J B , Sukumar N , Bennett K P , Cramer S , Tugcu N 2002 *J. Chem. Inform. Comput. Sci.* **42** 1347
- [18] Camps-Valls G , Soria-Olivas E , Pérez-Ruixo J J , Pérez-Cruz F , Figueiras-Vidal A R , Artés-Rodríguez A 2002 *Electron. Lett.* **38** 568
- [19] Cai C Z , Han L Y , Ji Z L , Chen Y Z 2004 *Proteins* **55** 66
- [20] Tasgetiren M F , Liang Y C , Sevcli M , Gencyilmaz G 2007 *Eur. J. Oper. Res.* **177** 1930
- [21] Ourique C O , Biscuaia E C , Pinto J C 2002 *Comput. Chem. Eng.* **26** 1783

Density prediction of selective laser sintering parts based on support vector regression^{*}

Cai Cong-Zhong[†] Pei Jun-Fang Wen Yu-Feng Zhu Xing-Jian Xiao Ting-Ting

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

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

Abstract

The support vector regression (SVR) approach combined with particle swarm optimization for parameter optimization , is proposed to establish a model for estimating the density of selective laser sintering parts under processing parameters , including layer thickness , hatch spacing , laser power , scanning speed , ambient temperature , interval time and scanning mode . A comparison between the prediction results and the results from the BP neural networks strongly supports that the internal fitting capacity and prediction accuracy of SVR model are superior to those of BP neural networks under the identical training and test samples ; the generation ability of SVR model can be efficiently improved by increasing the number of training samples . The minimum error value is provided by leave-one-out cross validation test of SVR . These results suggest that SVR is an effective and powerful tool for estimating the density of selective laser sintering parts .

Keywords : selective laser sintering , density , support vector machines , 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) .

[†] E-mail : caiczh@gmail.com