

静电喷头雾化特性预测模型^{*}

刘春景^{1,2} 郑加强¹ 王科元³

(1. 南京林业大学机械电子工程学院, 南京 210037; 2. 蚌埠学院机电系, 蚌埠 233030;
3. 石河子大学机电工程学院, 石河子 832000)

【摘要】 将一种基于改进粒子群优化最小二乘支持向量机的预测模型引入静电喷雾雾化性能预测领域, 并给出了相应的步骤和算法。该模型能方便地预测喷雾参数对喷头雾化性能的影响, 有助于正确认识喷头雾化性能随喷雾参数的变化规律。通过具体实例及与其他几种预测方法的对比表明, 在相同条件下, 其模型构造速度比标准 LS-SVM 方法高近 1 个数量级, 模型预测误差约为标准 LS-SVM 方法的 50%, 预测精度比常规 BP 模型高 1 个数量级。

关键词: 静电喷头 雾化性能 预测模型 改进粒子群优化最小二乘支持向量机

中图分类号: TQ027.3⁺2; TQ051.7⁺3

文献标识码: A

Prediction Model for Atomization Performance of Electrostatic Spraying Nozzle

Liu Chunjing^{1,2} Zheng Jiaqiang¹ Wang Keyuan³

(1. College of Mechanical & Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China

2. Department of Mechanical & Electronic Engineering, College of Bengbu, Bengbu 233030, China

3. College of Mechanical & Electronic Engineering, Shihezi University, Shihezi 832000, China)

Abstract

On the basis of analyzing disadvantages of conventional prediction model, a novel prediction model based on modified PSO least square support vector machine was proposed. Based on the new model, the design steps and learning algorithm were given. The practical experimental results show that the construction speed of this modified PSO LS-SVM model is 10 times less than that of the LS-SVM model, while the prediction error is 50%. Moreover, compared with BP model, the prediction accuracy is about 10 times higher than that of the former. The effects of electrostatic spraying parameters on atomization performance of electrostatic spraying nozzle can be predicted with the limited test data. Thus the variation law of atomization performance of electrostatic spraying nozzle following electrostatic spraying parameters can be obtained.

Key words Electrostatic spraying nozzle, Atomization performance, Prediction model, Modified PSO least square support vector machine

引言

为实现静电喷头雾化特性^[1-4]预测进而控制雾化质量的目的, 需要建立精度高、泛化能力强的雾

化特性预测模型。以往建立预测模型主要采用回归分析法、人工神经网络 (artificial neural network, 简称 ANN) 法, 它们都是基于传统的经验风险最小化原则 (empirical risk minimization, 简称 ERM), 根据

收稿日期: 2008-08-18 修回日期: 2008-10-08

^{*} 国家“十一五”科技支撑计划资助项目(2006BAD08A1203)和安徽省教育厅青年教师资助项目(2007jq1126)

作者简介: 刘春景, 博士生, 蚌埠学院副教授, 主要从事现代机械设计理论与方法研究, E-mail: liusun7575@163.com

通讯作者: 郑加强, 教授, 博士生导师, 主要从事植保机械、现代机械设计理论与方法、测控技术等研究, E-mail: jqzheng@njfu.edu.cn

给定的训练样本对系统输入、输出之间的依赖关系进行估计,对于大样本集一般以经验风险代替期望风险,经常能给出较好的结果^[5~6],但在具有小样本的雾化性能预测中,ERM原则并不能保证期望预测风险最小化。

基于结构风险最小化(structural risk minimization,简称SRM)准则的支持向量机(SVM)^[7~8]能够有效地避免经典学习方法中存在的过学习、维数灾难、局部极小等问题,且具有良好的泛化能力,在各种分类问题中已得到成功应用,但对于实际大规模问题则存在训练速度较慢的缺点。为此,提出最小二乘支持向量机(least square support vector machine,简称LS-SVM)^[9~10],把二次优化问题转换为一个线性方程组的求解问题,克服了SVM的缺陷。但LS-SVM算法在求解过程中会出现矩阵的求逆,对于实际工程的大规模问题在微机难以实现。基于迭代计算思想,本文采用再现群智能的粒子群优化算法(particle swarm optimization,简称PSO)来求解LS-SVM中的任意线性方程组;然后利用正交设计法安排静电喷雾试验和对其结果进行正交分析,研究影响雾化性能的主次关系,找出各参数水平高低对雾化性能的影响程度;再利用改进的最小二乘支持向量机智能算法对试验结果进行回归,建立静电喷雾雾化特性的智能预测模型;最后与基本最小二乘支持向量机和神经网络智能预测方法进行对比分析,来验证所提智能预测方法的可行性。

1 基本LS-SVM与改进算法

1.1 基本LS-SVM原理

设某一待回归系统的输入、输出样本数据集为 $\{x_i, y_i\} (i=1, 2, \dots, N)$ 。其中 x_i 为 n 维系统的输入向量, $x_i \in \mathbf{R}^n$; y_i 为系统输出, $y_i \in \mathbf{R}$ 。SVM系统辨识方法是:通过非线性变换 $\varphi(\cdot)$ 将 n 维输入样本 x 从原空间映射到高维特征空间 F ,并在此空间中构造最优线性回归函数

$$f(x) = \omega^T \varphi(x) + b \quad (1)$$

式中 $\varphi(x)$ ——非线性变换函数

ω ——线性回归系数

b ——模型偏移量

LS-SVM回归算法选择误差 ξ_i 的二范数为损失函数^[9],其优化问题为

$$\begin{cases} \min \left(\frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^N \xi_i^2 \right) \\ \text{s.t. } y_i = \omega^T \varphi(x_i) + b + \xi_i \quad (i=1, 2, \dots, N) \end{cases} \quad (2)$$

式中, ξ_i 为模型样本回归误差,正实数 γ 是调节常数,它能够使训练误差和模型复杂度之间取一个折衷以便使所求的函数具有较好的泛化能力,并且 γ 值越大,模型的回归误差越小。

引入Lagrange函数进行求解

$$L(\omega, b, \xi, a) = \frac{1}{2} \omega^T \omega + \gamma \sum_{i=1}^N \xi_i^2 - \sum_{i=1}^N a_i [\omega^T \varphi(x_i) + b + \xi_i - y_i] \quad (3)$$

式中 a_i ——Lagrange乘子

最优的 a 和 b 可以通过库恩-塔(karush-kuhn-tucker,简称KKT)条件获得,即优化函数对各变量的偏导数在鞍点处应为零^[8],有

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \omega = \sum_{i=1}^N a_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N a_i = 0 \\ \frac{\partial L}{\partial \xi} = 0 \rightarrow a_i = \gamma \xi_i \\ \frac{\partial L}{\partial a} = 0 \rightarrow \omega^T \varphi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (4)$$

对式(4)结果消去 ω 和 ξ ,优化问题转换为求解如下方程

$$\begin{bmatrix} 0 & \Theta^T \\ \Theta & \Omega + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (5)$$

其中

$$y = [y_1 \ y_2 \ \dots \ y_N]^T$$

$$\Theta = [1 \ 1 \ \dots \ 1]^T \quad a = [a_1 \ a_2 \ \dots \ a_n]^T$$

式中, Ω 为一方阵,其第 i 行第 j 列元素为 $\Omega_{ij} = \Psi(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$, $\Psi(\cdot)$ 是满足Mercer条件的对称函数。

LS-SVM系统回归结果为

$$y(x) = \sum_{i=1}^N a_i \Psi(x_i, x) + b \quad (6)$$

从上述的推导过程可见,LS-SVM辨识算法选用与标准SVM不同的损失函数,并用等式约束将求解二次规划问题转换为求解线性方程,显然可以极大地降低算法的复杂性,并提高辨识过程的抗干扰能力。

1.2 改进的LS-SVM

将式(5)改写为矩阵方程

$$\mathbf{A} \mathbf{X} = z \quad (\mathbf{A} \in \mathbf{R}^{m \times n}, z \in \mathbf{R}^m) \quad (7)$$

在LS-SVM中,一般是采用最小二乘法求解。而对于实际工程的大规模问题,由于 $\mathbf{A}^T \mathbf{A}$ 的维数较大,拟将矩阵方程(7)转换为采用PSO算法来迭代求解最优粒子 $\mathbf{X} = (x_1, x_2, \dots, x_n)^T$ 的问题,以避免矩阵求逆的过程。

基本PSO算法^[11]是由Kennedy和Eberhart最

早提出的,粒子通过跟踪 2 个极值来更新自己的速度 v_i 和位置 x_i ,即局部极值 p_{best} 和全局极值 g_{best} 。迭代更新公式为

$$v_{i+1} = v_i + \varphi_1 r_1 (p_{\text{best}} - x_i) + \varphi_2 r_2 (g_{\text{best}} - x_i) \quad (8)$$

$$x_{i+1} = x_i + v_{i+1} \quad (9)$$

式中 φ_1, φ_2 ——加速常数

r_1, r_2 ——随机参量

改进 PSO 算法^[12]即在基本 PSO 算法模型的基础上增加了收敛因子 χ 、惯性权重 μ 和约束因子 α , 保证算法的收敛性,提高收敛速度。粒子迭代公式为

$$v_{i+1} = \chi [\mu v_i + \varphi_1 r_1 (p_{\text{best}} - x_i) + \varphi_2 r_2 (g_{\text{best}} - x_i)] \quad (10)$$

$$x_{i+1} = x_i + \alpha v_{i+1} \quad (11)$$

采用改进的 PSO 算法求解矩阵方程,与基本 PSO 算法相比收敛速度快,计算精度高^[12]。

2 PSO 优化的 LS-SVM 静电喷头预测模型

图 1 为试验喷头(采用气液双流体雾化和感应充电)。从静电喷雾的机理和过程可知,影响雾化性能的因素很多,其中最重要的因素是气体压力 p_a 、液体压力 p_l 、喷孔直径 d 和充电电压 U 。由于影响因素与雾化性能之间存在一种复杂的非线性映射关系,很难通过分析喷雾雾化过程机理建模。为此,拟直接通过试验数据建立基于 PSO 迭代优化的 LS-SVM 回归预测模型,将对雾化性能机理的分析转换为预测模型参数的辨识问题。




图 1 气助式静电喷头结构图

Fig. 1 Structure of pneumatic electrostatic nozzle

(a) 结构图 (b) 三维图

1. 喷孔片 2. 环形电极 3. 喷嘴帽 4. 进气管 5. 喷嘴体

具体步骤为:

(1) 静电喷头雾化性能试验。通过改变喷雾参数 (p_a, p_l, d, U) 进行反复试验,测定雾滴直径,计算出表征雾化质量的体积中径 (VMD)、数量中径 (NMD)、均匀度 (DR) 和雾滴直径标准差 (STD),记录喷雾参数与表征雾化质量的参数对应关系。

(2) 组成训练样本集。利用原始试验数据构造 PSO 迭代优化的 LS-SVM 回归模型训练样本集

$\{x_i, y_i\}$, i 为试验编号。其中,输入参数 x_i 为多维向量,由影响雾滴直径的主要参数构成,此处 x_i 由 p_a, p_l, d 和 U 构成;输出参数 y_i 为 i 号试验的表征雾化质量的参数。

(3) 初始化粒子群。设定粒子群参数,在定义空间 \mathbf{R}^n 中随机产生 n 个粒子 x_1, x_2, \dots, x_n ,组成初始种群 $\mathbf{X}(t)$;随机产生各粒子的初始速度 v_1, v_2, \dots, v_n ,组成速度矩阵 $\mathbf{v}(t)$;每个粒子的个体最优解 $p_{\text{best},i}$ 初始值为 x_i 的初始值。

(4) 评价各粒子适应度函数 $f(x)$ 。在具体矩阵方程求解中,可以按照残差 ($z - \mathbf{A}x$) 的均方差来计算适应度函数, $f(x)$ 越小,适应能力越强。适应度函数定义为

$$f(x) = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (z_i - A_{ij} x_j)^2 \quad (12)$$

(5) 对每个粒子,比较当前适应度 $f(x_i)$ 和历史最好位置适应度 $f(p_{\text{best},i})$,如果 $f(x_i) < f(p_{\text{best},i})$,那么 $p_{\text{best},i} = x_i$,即可比较群体所有粒子当前适应度 $f(x_i)$ 和群体最好位置适应度 $f(g_{\text{best},i})$,如果 $f(x_i) < f(g_{\text{best},i})$,那么全局最优解 $g_{\text{best},i} = x_i$ 。

(6) 根据改进 PSO 算法式(10)和(11)更新粒子的速度和位置,产生新种群 $\mathbf{X}(t+1)$,速度调整规则为

$$v_i = \begin{cases} v_{\max} & (v_i > v_{\max}) \\ -v_{\max} & (v_i \leq -v_{\max}) \end{cases} \quad (13)$$

(7) 检查结束条件。若满足条件,则结束寻优,返回当前最优个体为结果,否则 $T = T + 1$,转至步骤(2)。设定结束条件为寻优达到最大迭代次数 T_{max} 或评价值小于给定精度。

(8) 输出结果。输出所求得的矩阵方程的最小二乘解,即对应式(5)中最优参数 b 和 $\{a_i\}_{i=1}^N$ 。

(9) 对静电喷头进行喷雾性能预测时,将预测模型参数 $\{a_i\}_{i=1}^N$ 和 b 代入式(6)中,即可建立基于 LS-SVM 的智能预测模型。

将该试验号过程参数 x_i 输入到 LS-SVM 智能预测模型,得到模型响应 \hat{y}_i ,即为该试验号的表征雾化质量的参数预测值。与实际测量值 y_i 进行对比,可求得预测误差。

根据泛函理论,高维空间的内积计算可以用原输入空间的一个核函数等效,所以在处理非线性问题时可以不作非线性变换,而直接采用核函数代替内积计算,从而解决了高维计算问题。引入核函数是支持向量机得以成功应用的重要原因之一。核函数是满足 Mercer 条件的任意对称函数 $\varphi(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{(\mathbf{x} - \mathbf{y})(\mathbf{x} - \mathbf{y})^T}{2\delta^2}\right)$,选取径向基函数为核函数, δ 为核函数的宽度。

3 试验设计与分析

3.1 试验条件

图2为静电喷头试验装置示意图。静电喷头喷雾过程关键参数对雾化性能影响试验条件为:试验在室内进行,环境温度 $20\sim 22^{\circ}\text{C}$,相对湿度 $88\%\sim 89\%$,试剂为不含杂质的自来水加红色颜料。采用纸卡法采样,取样纸为 $10\text{ cm}\times 12\text{ cm}$ 静电复印用白纸,沿喷雾轴线下方 1 m 采集雾滴样本,持续取样时间 $1\sim 2\text{ s}$ 。采用自行研制的电压为 $1\sim 12\text{ kV}$ 、电流为 $1\sim 9\text{ mA}$ 直流静电高压电源,充电方式采用正高压;选用Winner313型喷雾激光粒度分析仪获取雾滴粒径分布情况。




图2 静电喷头试验装置示意图

Fig.2 Experimental equipment sketch map of pneumatic electrostatic nozzle

1. 液泵 2. 液压调节阀 3. 高压静电发生器 4. 喷头及喷杆
5. 高压导线 6. 机架 7. 气压调节阀 8. 安全阀 9. 气压表
10. 空气压缩机 11. 药液箱

3.2 试验因素和水平

通过对静电喷雾机理及试验条件的分析,选择 p_a 、 p_t 、 d 和 U 4个因素,分别用A、B、C和D表示,考察喷雾参数对喷头雾化性能的影响,结合喷雾参数的最优化值,每个参数选出3个不同的水平数值。因素及所取水平如表1所示。为研究各试验因素及其交互作用对雾滴直径的影响,并考虑尽量减少试验次数,采用 $L_{27}(3^{13})$ 正交表设计试验方案,由雾滴直径样本计算出VMD、NMD、DR和STD。

表1 试验因素与水平

Tab.1 Experimental factors and the factor levels

水平	试验因素			
	气体压力	液体压力	喷孔直径	充电电压
	A/MPa	B/MPa	C/mm	D/kV
1	0.2	0.20	1.5	1
2	0.3	0.25	2.0	3
3	0.4	0.30	2.5	6

3.3 试验结果及分析

由雾滴直径样本计算出表征雾化质量的VMD、NMD、DR和STD,与相应的因素水平如表2

所示。

表2 试验结果

Tab.2 Experimental results

试验序号	试验因素				试验结果			
	A	B	C	D	VMD/ μm	NMD/ μm	DR	STD/ μm
1	1	1	1	1	46.44	38.99	0.84	12.62
2	1	1	2	2	43.00	34.40	0.80	11.72
3	1	1	3	3	41.28	36.12	0.87	8.56
4	1	2	1	2	43.57	34.97	0.80	11.84
5	1	2	2	3	49.45	43.00	0.87	11.15
6	1	2	3	1	45.15	40.42	0.89	10.76
7	1	3	1	3	48.73	42.14	0.86	12.35
8	1	3	2	1	57.66	49.45	0.86	11.27
9	1	3	3	2	46.87	42.14	0.90	9.54
10	2	1	1	2	43.00	35.83	0.83	11.23
11	2	1	2	3	38.70	34.40	0.89	9.21
12	2	1	3	1	39.99	32.25	0.81	9.76
13	2	2	1	3	40.13	35.83	0.89	10.34
14	2	2	2	1	40.85	34.83	0.85	9.44
15	2	2	3	2	42.14	36.55	0.86	9.20
16	2	3	1	1	43.00	36.41	0.85	11.34
17	2	3	2	2	43.00	36.55	0.85	8.93
18	2	3	3	3	38.70	34.40	0.89	10.28
19	3	1	1	3	52.17	40.13	0.76	13.33
20	3	1	2	1	38.70	32.68	0.84	10.76
21	3	1	3	2	36.55	33.54	0.92	8.25
22	3	2	1	1	50.17	43.00	0.86	11.43
23	3	2	2	2	35.26	30.10	0.85	8.86
24	3	2	3	3	38.70	30.10	0.78	9.46
25	3	3	1	2	43.00	36.98	0.86	11.55
26	3	3	2	3	39.56	35.26	0.89	8.98
27	3	3	3	1	38.70	34.40	0.89	8.11

雾滴体积中径回归方程显著性检验结果如表3所示。由表中可知,雾滴体积中径回归方程的显著性检验结果为极显著,说明可以用雾滴体积中径回归模型来描述气助式静电喷头雾滴体积中径与各试验因素的关系,且具有较高的精度。试验因素对应回归参数的显著性检验结果表明,气体压力和喷孔直径显著性为极显著(尾概率为0.005和0.020),说明这2个因素是影响雾滴体积中径的主导因素。

在各影响因素中,液体压力、喷孔直径和液体流量对雾滴直径均匀度的影响显著(显著性水平为0.05),大气压力和喷孔直径的交互作用影响显著,其他因素及交互作用影响不显著。这表明,只要控制好这几个影响因素就可使雾化均匀性达到稳定状态,且具有理想的均匀度。

表 3 雾滴体积中径回归方程的显著性检验

Tab.3 Significance test of droplet VMD regression equation

方差来源	自由度	平方和	均方	F 值	尾概率 $P_r > F$
模型	6	0.155	0.026	2.771	0.040
误差	20	0.186	0.009		
总和	26	0.341			

方差来源	自由度	参数估计值	标准差	t 值	尾概率 $P_r > F$
β_0		3.240	0.098	37.234	<0.000 1
β_1	1	-0.014	0.009	-0.599	0.555
β_2	1	-0.437	0.063	-3.097	0.005
β_3	1	-0.343	0.085	-2.491	0.020
β_4	1	0.652	0.494	1.091	0.286
β_5	1	-0.110	0.121	0.800	-0.053
β_6	1	0.200	0.130	0.366	0.189

4 静电喷头雾化性能建模实例

对表 2 的试验数据,分别用 BP 神经网络、LS-SVM 和 PSO 迭代优化的 LS-SVM 进行建模对比试验。其中 BP 神经网络由 Matlab 中 ANN 工具箱提供,其学习率为 0.2,训练步数设为 10 000 步,网络初值取[0,1]的随机数,隐含层神经元个数分别取 9,12 进行试验。LS-SVM 算法直接利用 Matlab 矩阵功能实现,核宽度 δ 取 0.45,惩罚系数 γ 取 500,核函数选用回归精度较高的径向基 $\varphi(\mathbf{x}, \mathbf{y}) =$

$$\exp\left(\frac{-(\mathbf{x} - \mathbf{y})(\mathbf{x} - \mathbf{y})^T}{2\delta^2}\right)$$

试验时所用计算机为 Pentium M - 2.0 GHz CPU,512 MB 内存。表 4 给出了 4 种方法构造预测模型的耗时及训练样本学习精度的对比情况。

表 4 用 BP 神经网络、LS-SVM 和改进 LS-SVM 方法进行雾化性能预测建模对比

Tab.4 Comparison of BP neural network, LS-SVM and modified PSO LS-SVM predictor

参数	建模方法			
	BP(3,1)	BP(10,1)	LS-SVM	改进 LS-SVM
耗时/s	22.1	25.4	0.08	0.03
均方误差	0.015 3	0.004 2	1.5×10^{-5}	6×10^{-6}

从表 4 中不难看出,基于 PSO 迭代优化的 LS-SVM 模型训练样本的均方误差(mean square error, 简称 MSE)与 BP 神经网络建模方法相比降低了 3~4 个数量级,相对 LS-SVM 建模方法降低了 1 个数量级,基于 PSO 迭代优化的 LS-SVM 耗时最小,比 BP 建模方法快 1~2 个数量级,相对 LS-SVM 建模方法快近 1 个数量级。

再用试验值以外的参数值进行喷雾试验,将实际得到的雾滴直径值及 VMD、NMD 和 DR 与所建预测模型输出结果进行对比,对比结果如表 5 所示。

表 5 静电喷雾雾化质量预测结果对比

Tab.5 Comparison of prediction results of electrostatic spraying atomization performance

序号	试验因素				试验结果				
	p_a	p_l	d	U	VMD/ μm	NMD/ μm	DR		
	1	0.4	0.30	1.0	3	53.342 8	45.524 3	0.785 6	
2	0.5	0.35	2.5	5	59.155 8	50.462 7	0.824 2		
3	0.5	0.40	3.0	7	60.402 3	51.521 6	0.894 2		
4	0.6	0.45	2.0	8	61.423 5	52.389 2	0.898 6		
预测值									
				BP(9,1)		BP(12,1)			
				VMD/ μm	NMD/ μm	DR	VMD/ μm	NMD/ μm	DR
1	53.592 1	45.775 8	1.035 2	53.413 5	45.592 1	0.852 4			
2	59.402 8	50.815 6	1.082 4	59.376 0	50.682 2	0.708 8			
3	60.154 5	51.252 2	0.642 4	60.512 2	51.415 6	0.788 4			
4	61.178 6	52.122 5	0.625 5	61.641 5	52.602 4	0.785 4			
MSE	0.061 8	0.062 2	0.064 6	0.028 2	0.026 3	0.024 2			
预测值									
				LS-SVM		改进 LS-SVM			
				VMD/ μm	NMD/ μm	DR	VMD/ μm	NMD/ μm	DR
1	53.253 5	45.532 1	0.851 2	53.413 5	45.442 1	0.812 2			
2	59.214 8	50.512 4	0.782 4	59.125 2	50.432 2	0.805 4			
3	60.322 2	51.601 2	0.825 6	60.464 0	51.492 0	0.875 3			
4	61.482 8	52.324 2	0.854 5	61.728 2	52.322 2	0.865 5			
MSE	0.005 2	0.005 6	0.005 2	0.002 6	0.002 9	0.002 4			

预测结果表明,基于 PSO 迭代优化的 LS-SVM 预测模型效果最佳,其预测均方误差仅为 LS-SVM 方法的 50%,为 BP 预测模型的 10%。

5 结论

(1) 本文提出了一种基于改进粒子群优化 LS-SVM 的静电喷头雾化质量预测方法。实际预测结果表明,改进的 LS-SVM 模型预测结果明显优于 LS-SVM 模型和 BP 预测模型。应用改进的 LS-SVM 算法进行模型学习训练的效率比经典 LS-SVM 算法高得多,特别是对于大规模数据建模问题,改进的 LS-SVM 算法具有很强的优势和良好的应用前景。

(2) 对所建立的预测模型分别从理论和试验两方面进行验证。结果表明,本模型可很好地描述气体压力 p_a 、液体压力 p_l 、喷孔直径 d 和充电电压 U 4 个因素对静电喷头雾化质量的影响。

参 考 文 献

- 1 任惠芳,韩学猛,王玉顺.气力式静电喷头雾化特性研究[J].山西农业大学学报,2003,23(2):148~151.
Ren Huifang, Han Xuemeng, Wang Yushun. Atomization peculiarities of pneumatic energy electrostatic spray nozzle[J]. Journal of Shanxi Agricultural University, 2003, 23(2): 148~151. (in Chinese)
- 2 何雄奎,严苛荣,储金宇,等.果园自动对靶静电喷雾机设计与试验研究[J].农业工程学报,2003,19(6):78~80.
He Xiongkui, Yan Kerong, Chu Jinyu, et al. Design and testing of the automatic target detecting, electrostatic, air assisted, orchard sprayer[J]. Transactions of the Chinese Society of Agricultural Engineering, 2003, 19(6): 78~80. (in Chinese)
- 3 Maski D. Spray chargeability studies and data modeling using electrostatic spraying system for drift mitigation[C]. ASAE Annual International Meeting, Florida, Paper Number 051153, 2005.
- 4 Kim C, Hung Y C. Development of a response surface model of an electrostatic spray system and its contributing parameters[J]. Transactions of the ASABE, 2007, 50(2): 583~590.
- 5 Wang X, Feng J C X. Development of empirical models for surface roughness prediction in finish turning[J]. International Journal of Advanced Manufacturing Technology, 2002, 20(5): 348~356.
- 6 Benardos P G, Vosniakos G C. Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiment[J]. Robotics and Computer-integrated Manufacturing, 2002, 18(5): 343~354.
- 7 Vapnik V N. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1999.
- 8 Vapnik V N. An overview of statistical learning theory[J]. IEEE Transaction Neural Networks, 1999, 10(5): 988~999.
- 9 Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293~300.
- 10 Suykens J A K, Vandewalle J. Sparse least squares support vector machine classifiers[C] // European Symposium on Artificial Neural Networks, Bruges Belgium, 2000: 37~42.
- 11 Kennedy J, Eberhart R C. Particle swarm optimization[C] // Proc. IEEE Int. Conf. Neural Networks, Piscataway, NJ: IEEE Press, 1995, 1942~1948.
- 12 Shi Y, Eberhart R. A modified particle swarm optimizer[C] // IEEE World Congress on Computational Intelligence, 1998: 69~73.
- 13 茹煜,郑加强,周宏平,等.航空双喷嘴静电喷头的设计与试验[J].农业机械学报,2007,38(12):58~61,57.
Ru Yu, Zheng Jiaqiang, Zhou Hongping, et al. Design and experiment of double-nozzle of aerial electrostatic sprayer[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007, 38(12): 58~61, 57. (in Chinese)