

研究论文

# 免疫 PSO \_ WLSSVM 最优聚丙烯熔融指数预报

蒋华琴, 刘兴高

(浙江大学控制系工业控制技术国家重点实验室, 浙江 杭州 310027)

**摘要:** 熔融指数 (MI) 是聚丙烯生产的重要指标, 建立可靠的熔融指数预报模型非常重要。针对标准粒子群算法 (PSO) 在迭代过程中易出现粒子过早收敛而陷入局部最优的缺陷, 通过引入免疫系统的抗体选择机制, 构造了一种基于免疫机制的免疫粒子群优化算法 (ICPSO), 来保持更新粒子的多样性, 从而克服标准粒子群算法过早收敛的缺陷; 然后利用 ICPSO 方法对鲁棒最小二乘支持向量机预报模型 (WLSSVM) 进行参数寻优, 得到最优的 ICPSO \_ WLSSVM 预报模型。以实际聚丙烯生产的熔融指数预报作为实例进行研究, 结果表明所提出的 ICPSO \_ WLSSVM 模型的有效性和良好的预报精度。

**关键词:** 免疫粒子群优化; 多样性; 支持向量机; 熔融指数预报; 参数寻优

**DOI:** 10.3969/j.issn.0438-1157.2012.03.027

**中图分类号:** TQ 274

**文献标志码:** A

**文章编号:** 0438-1157 (2012) 03-0866-07

## Optimal melt index prediction based on ICPSO \_ WLSSVM algorithm for industrial propylene polymerization

JIANG Huaqin, LIU Xinggao

(State Key Laboratory of Industrial Control Technology, Department of Control Science & Engineering,  
Zhejiang University, Hangzhou 310027, Zhejiang, China)

**Abstract:** Melt index (MI) is considered as one of the important quality variables of propylene (PP) polymerization, which determines the products specifications. Thus, a reliable estimation of MI is crucial in quality control. Addressing the deficiency of the particle swarm optimization (PSO) algorithm, whose particles are easy to sink into premature convergence and run into local optimization in the iterative process, this article introduces the selection strategy, the immune clone PSO (ICPSO) algorithm, which makes the particles of ICPSO maintain the diversity during the iterative process so as to overcome the premature convergence of PSO. The ICPSO was used to optimize the parameters of weighted least support vector machine (WLSSVM) to predict the melt index of polypropylene, so the optimized model ICPSO \_ WLSSVM was obtained. Researches on the optimized model were illustrated with the real plant of propylene polymerization, and the results showed that the proposed approach had great prediction accuracy and validity.

2011-05-30 收到初稿, 2011-11-23 收到修改稿。

**联系人:** 刘兴高。第一作者: 蒋华琴 (1984—), 女, 硕士研究生。

**基金项目:** 国家自然科学基金项目 (U1162130); 浙江省杰出青年科学基金项目 (R4100133); 浙江省科技厅国际合作项目 (2009C34008); 国家高技术研究发展计划项目 (2006AA05Z226)。

**Received date:** 2011-05-30.

**Corresponding author:** Prof. LIU Xinggao, lxxg@zju.edu.cn

**Foundation item:** supported by the National Natural Science Foundation of China (U1162130), the Zhejiang Provincial Natural Science Foundation for Distinguished Young Scientists (R4100133), the International Cooperation and Exchange Project of Science and Technology Department of Zhejiang Province (2009C34008) and the High-tech Research and Development Program of China (2006AA05Z226).

**Key words:** immune clone particle swarm optimization; diversity; support vector machine; melt index prediction; parameters optimization

引 言

聚丙烯是工业三大塑料之一，是重要的工业原料。我国是聚丙烯消费大国，虽然聚丙烯工业发展迅速，但仍不能满足国内实际生产需要，可见聚丙烯生产控制研究意义显著。熔融指数是聚丙烯生产控制的主要质量指标之一，决定了产品的牌号。所以聚丙烯熔融指数的准确预报也就变得尤为重要。但是目前熔融指数的预报大多采用离线化验分析的方法获得，存在 2~4 h 的滞后，无法满足实时控制的要求<sup>[1]</sup>。因此，设计一个准确、可靠的熔融指数实时预报模型成为了聚丙烯生产控制研究中的前沿和热点。

图 1 为聚丙烯生产中典型的 Hypol 工艺流程图，由此可知聚丙烯生产过程的复杂性。目前，基于数据驱动的软测量方法应用广泛。王桂增等<sup>[2-3]</sup>在 1999 年提出了一种具有鲁棒自适应功能的 RBF 网络方法，2002 年提出了机理和统计的两种建模方法；孔薇等<sup>[4]</sup>于 2003 年提出了结合 PCA、PLS 和 RBF 的模型；Han 等<sup>[5]</sup>研究了结合 SVM、PLS 和神经网络的模型；Liu 等<sup>[6-8]</sup>先后提出了基于多尺度分析的 ICA-MS-RBF 模型、PCA-MS-RBF 模型和 WLS-SVM 模型；Zhang 等<sup>[9]</sup>提出基于 Bootstrap 多神经网络的软测量方法。在此基础上，最近几年很多人引入优化算法，提高了模型的准确性。优化方法主要包括遗传算法、模拟退火、蚁群优化算法、粒子群优化算法等。

神经网络虽然有较好的非线性逼近能力，但仍然存在收敛速度慢、容易陷入局部极小问题。支持向量机（SVM）是一种新的机器学习方法。和神经网络相比，SVM 使用了 VC 维理论和结构风险最小原理，很好地解决了小样本、非线性、高维数、局部极小问题<sup>[10]</sup>。在 SVM 基础上提出的鲁棒最小二乘支持向量机（WLSSVM）方法，求解的是线性方程组，减小了 SVM 算法的复杂性，并且提高了 SVM 的鲁棒性<sup>[11-12]</sup>。

本文在对标准 PSO 算法原理分析的基础上，引入生物免疫能力，提出免疫粒子群算法（ICPSO）。ICPSO 算法设立记忆单元，引入克隆抑制机制和选择机制，保持粒子更新的多样性，从而避免 PSO 算法的早熟收敛现象。利用 ICPSO 算法对 WLSSVM 模型进行参数寻优，得到最优的 ICPSO \_ WLSSVM 预报模型，采用此模型对某厂聚丙烯生产装置的 DCS 历史库分析化验采集的现场数据进行了研究。

1 加权最小二乘支持向量机与免疫粒子群优化算法

1.1 加权最小二乘支持向量机

支持向量机（SVM）是近年来兴起的一种基于统计学理论的新型机器学习算法，以结构风险最小化为原则，能较好解决非线性和高维数的问题，在多行领域内得到应用<sup>[13]</sup>。Suykens 等<sup>[14-15]</sup>首次提出最小二乘支持向量机（LSSVM），用于解决分




图 1 丙烯聚合工艺流程  
Fig. 1 General scheme of propylene polymerization

类和函数估计问题,提高了学习速度。

为提高模型的稀疏性和鲁棒性,本文采用了加权最小二乘支持向量机(WLSSVM)<sup>[11]</sup>,在最小二乘支持向量机(LSSVM)的基础上引入权重因子 $v_i$ 。训练样本 $\{x_k, y_k\}_{k=1}^n$ ,其中, $x_k$ 是输入数据, $y_k$ 是输出数据。WLSSVM的函数估计问题描述为求解下面问题

$$\min_{\omega^*, b^*, \xi^*} J(\omega^*, \xi^*) = \frac{1}{2} \omega^{*T} \omega^* + \frac{1}{2} \gamma \sum_{i=1}^n v_i \xi_i^{*2} \quad (1)$$

满足约束条件

$$y_i = \omega^{*T} \phi(x_i) + b^* + \xi_i^* \quad i = 1, 2, \dots, n \quad (2)$$

式中 $\omega^*$ 是权向量, $\xi_i^* = \alpha_i / \gamma$ 是误差变量, $\gamma$ 是可调常数, $v_i$ 是权系数,用来权衡误差变量 $\xi_i^*$ 。

根据式(1),可定义拉格朗日函数

$$L(\omega^*, b^*, \xi^*, \alpha^*) = J(\omega^*, \xi^*) - \sum_{i=1}^n \alpha_i^* [\omega^{*T} \phi(x_i) + b^* + \xi_i^* - y_i] \quad (3)$$

对式(3)进行优化并消除 $\omega^*$ 、 $\xi^*$ ,可得以下矩阵方程

$$\begin{bmatrix} b^* \\ \alpha^* \end{bmatrix} = \begin{bmatrix} 0 & \mathbf{I}_n^T \\ \mathbf{I}_n & K + \mathbf{V}_\gamma \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (4)$$

式中 $\alpha^* = [\alpha_1^*, \dots, \alpha_n^*]^T$ , $\mathbf{I}_n$ 是 $n$ 维单元矩阵, $y = [y_1, \dots, y_n]^T$ , $K = \phi(x_i)^T \phi(x_j) = K(x_i, x_j)$ 为核函数,本文采用了RBF核,对角矩阵 $\mathbf{V}_\gamma$ 为

$$\mathbf{V}_\gamma = \text{diag}\{\frac{1}{\gamma v_1}, \dots, \frac{1}{\gamma v_n}\} \quad (5)$$

权系数 $v_i$ 的选择是根据LSSVM的误差变量 $\xi_i = \alpha_i / \gamma$ 来确定的。

$$v_i = \begin{cases} 1 & \text{if } |\xi_i / \hat{s}| \leq c_1 \\ \frac{c_2 - |\xi_i / \hat{s}|}{c_2 - c_1} & \text{if } c_1 \leq |\xi_i / \hat{s}| \leq c_2 \\ 10^{-4} & \text{其他} \end{cases} \quad (6)$$

式中 $\hat{s}$ 为 $\xi_i$ 的标准偏差的鲁棒估计, $c_1 = 2.5$ , $c_2 = 3$ 。

## 1.2 粒子群优化算法

粒子群优化(particle swarm optimization)算法是一种基于群体智能的进化算法。该算法是通过搜索空间中的粒子来得到优化问题的解<sup>[16]</sup>。每一个粒子有其相应的速度、位置来更新自己,算法是通过由目标函数决定的适应度来评价粒子的优劣。目前,PSO及改进PSO已经得到广泛应用<sup>[17-18]</sup>。

首先初始一群随机粒子,每个粒子表示优化问题的一个可能解,通过迭代找到最优解。每次迭代中,粒子都是通过两个极值来更新自己:一个是粒

子本身找到的最优解,即个体最优解 $p_{\text{best}}$ ;一个是整个粒子群当前找到的最优解 $g_{\text{best}}$ 。PSO算法中,每个粒子的速度和位置根据式(7)和式(8)进行。

$$v_{k+1}^i = \omega_k v_k^i + d_1 r_1 (p_{\text{best}} - x_k^i) + d_2 r_2 (g_{\text{best}} - x_k^i) \quad (7)$$

$$x_{k+1}^i = x_k^i + v_{k+1}^i \quad i = 1, 2, \dots, N \quad (8)$$

式中 $v_k^i$ 是粒子当前的速度; $x_k^i$ 是粒子的当前位置; $r_1$ 、 $r_2$ 是 $[0, 1]$ 之间的随机数; $d_1$ 、 $d_2$ 是学习因子; $\omega_k$ 是加权系数,一般在 $0.1 \sim 0.9$ 之间。如果加权系数随迭代而线性减小,将显著改善算法的收敛性能。设 $\omega_{\text{max}}$ 为最大加权系数, $\omega_{\text{min}}$ 为最小加权系数, $k$ 为当前迭代次数,iter<sub>max</sub>为最大迭代次数,则

$$\omega_k = \omega_{\text{max}} - (\omega_{\text{max}} - \omega_{\text{min}})(k - 1) / \text{iter}_{\text{max}} \quad (9)$$

算法结束条件为 $k$ 达到设定值或群体适应度达到一定要求。

## 1.3 免疫粒子群优化算法

标准PSO算法以其简单易行及快速收敛的特性得到了快速发展,但也存在容易陷入局部最优的问题,且搜索速度有待进一步提高。文献[19]提出了免疫遗传算法。本文采用免疫PSO算法,来改善标准PSO的缺陷。

免疫系统具有抗体多样性和自我调节能力。在免疫调节中,那些与抗原亲和力大并且浓度较低的抗体会受到促进,而与抗原亲和力小或浓度较高的抗体将会受到抑制,以此保证抗体的多样性。自我调节能力是免疫系统具有的维持免疫平衡的机制,通过自我调节产生适当数量必要的个体,即大量繁殖类似最优个体的粒子。这样,在保留高适应度个体的同时,能保留个体的多样性,能避免早熟现象。这种将生物的免疫特性结合到PSO算法中就是免疫PSO算法。

本文采用基于浓度机制的多样性保持策略,使得新一代粒子中,各适应度层次的粒子维持在一定浓度。第 $i$ 个粒子的适应度定义如下

$$F(x_i) = \sum_{j=1}^N (y_i - \bar{y}_i)^2 / 2 \quad (10)$$

由式(10)可推导出基于粒子适应度的个体概率选择公式

$$P(x_i) = \alpha E \frac{[1 - F(x_i)]}{F(g_{\text{best}})} + \beta \frac{F(x_i)}{F(g_{\text{best}})} \quad (11)$$

式中 $N$ 为样本个数, $y_i$ 为真实值, $\bar{y}_i$ 为预测值, $\alpha$ 、 $\beta$ 是 $[0, 1]$ 之间的随机数, $F(x_i)$ 是第 $i$ 个粒

表 1 基准测试函数  
Table 1 Benchmark functions

Benchmark function	Dimension	Search space	Optimal value	Acceptable value
$f_1(x) = \sum_{i=1}^D x_i^2$	30	$[-100, 100]^D$	0	0.01
$f_2(x) = \sum_{i=1}^D  x_i  + \prod_{i=1}^D  x_i $	30	$[-10, 10]^D$	0	0.01
$f_3(x) = \sum_{i=1}^D (\lfloor x_i + 0.5 \rfloor)^2$	30	$[-100, 100]^D$	0	0
$f_4(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]^D$	0	50

子的适应度， $F(g_{\text{best}})$  是全局最优解的适应度， $E$  是抗体浓度，即具有相近适应度的抗体个数与群体中抗体总数的比值。

1.4 算法性能比较

为了比较免疫 PSO 算法和标准 PSO 算法，本节进行了基准测试。4 个基准函数见表 1。其中前 3 个基准测试函数具有单峰特性，后 1 个具有多峰特性。表 1 还具体给出了搜索空间维度，粒子取值范围。另外，表中还给出了理论最优值和可接受的最优值，作为性能比较的依据。

为了使得算法之间具有可比性，算法的种群规模都设为 20，每个算法在每个基准测试函数上计算  $2.0 \times 10^5$  次适应度函数。表 2 分别给出了每个算法在每个基准测试函数上经过 10 次独立运算得到的优化值的平均值（mean）。分析表中的数值可以得出：在所有基准测试函数上，免疫 PSO 算法都比标准 PSO 算法的优化精度要高。这也是 ICP-  
SO \_ WLSSVM 模型比 PSO \_ WLSSVM 模型的预报精度要高的原因。

表 2 算法优化精度比较  
Table 2 Comparison of optimization accuracy  
between algorithms

Function	Indicator	PSO	ICPSO
$f_1$	mean	$1.35 \times 10^{-26}$	$3.05 \times 10^{-55}$
$f_2$	mean	$9.02 \times 10^{-18}$	$1.21 \times 10^{-30}$
$f_3$	mean	0.11	0
$f_4$	mean	43.58	0.56

1.5 基于免疫 PSO 优化的 WLSSVM 的模型

WLSSVM 的优化目标函数如式(10) 所示。  
基于免疫 PSO 优化的 ICP-  
SO \_ WLSSVM 模型的算法步骤如下。

(1) 粒子群初始化。将 WLSSVM 模型参数  $(\gamma, \sigma^2)$  随机初始化为一群粒子。设定粒子群规模为  $N$ ，最大加权系数为  $w_{\text{max}}$ ，最小加权系数为

$w_{\text{min}}$ ，最大迭代次数为  $\text{iter}_{\text{max}}$ 。解空间维数定为 2。每个粒子的适应度为式(10)。

(2) 根据初始化的粒子群确定每个粒子的初始位置，由式(10) 计算每个粒子的适应度，找到初始个体最优粒子  $p_{\text{best}}$ ，取适应度最优的粒子的位置定位群体的初始最优粒子  $g_{\text{best}}$ 。

(3) 按式(7)~式(9) 更新每个粒子的速度和位置，重新计算每个粒子的适应度。将其与初始个体最优粒子适应度比较，若更优，则更新个体最优粒子，否则保留。

(4) 生成免疫粒子，计算免疫粒子的适应度，与  $p_{\text{best}}$  比较，将更优粒子放入记忆库。用式(11) 计算新粒子的选择概率，依概率大小选择新粒子替换原来适应度较差的粒子，克隆适应度较好的粒子形成新一代粒子群体。

(5) 将新一代粒子群体的个体最优粒子  $p_{\text{best}}$  与初始群体最优粒子  $g_{\text{best}}$  比较，更新群体最优粒子  $g_{\text{best}}$ 。

(6) 迭代次数  $K$  加 1，若达到最大迭代次数或群体最优解符合条件，则终止迭代，否则转到步骤(3) 继续执行。

(7) 将得到的群体最优解来作为  $\gamma, \sigma^2$  的参数，建立 ICP-  
SO \_ WLSSVM 模型进行预报。

2 熔融指数预报上的应用

根据图 1 所示的流程工艺和其中的反应机理，选择 9 个过程变量作为模型的输入变量，它们分别是温度、压力、液位、氢气气相体积分、3 股丙烯进料流速和 2 股催化剂进料流速。以某石化厂聚丙烯实际生产过程的生产数据作为建模和预报数据。总共有 85 组数据。

首先，对数据进行规范化，包括数据的中心化（去均值）和方差的归一化处理，然后采用主元分

析方法将数据降到 6 维。然后将数据分为训练数据集, 验证数据集和推广数据集, 三者取自不同的生产批次。其中训练数据集为 50 组, 验证数据集为 20 组, 推广数据集为 15 组。将训练数据集来训练 WLSSVM 模型, 得到初始的预报模型。再利用免疫 PSO 算法对 WLSSVM 的两个参数进行寻优, 得到优化后的 ICPSO \_ WLSSVM 预报模型, 优化后 WLSSVM 参数分别为  $\gamma = 224.705$ ,  $\sigma^2 = 3.0855$ 。PSO 参数选择为  $d_1 = d_2 = 2.0$ ,  $w_{\max} = 0.8$ ,  $w_{\min} = 0.2$ 。利用验证数据集对新模型的预报效果进行检验, 得到的结果与初始预报模型对验证数据集的预报结果进行了比较。再用推广数据集检验新模型的推广性。比较结果见表 3。

表 3 优化前后的 WLSSVM 预报模型  
对验证数据集的预报结果

Table 3 Prediction of WLSSVM models before and after optimization on test dataset				
Model	MAE	MRE/%	RMSE	STD
WLSSVM	0.0727	2.76	0.1172	0.1058
PSO_WLSSVM	0.0550	2.09	0.0986	0.0943
ICPSO_WLSSVM	0.0490	1.86	0.0905	0.0889

本文从 4 个指标来比较优化前后模型, 分别是平均绝对误差 (MAE), 平均相对误差 (MRE), 均方根误差 (RMSE), 标准差 (STD)。MAE、MRE、RMSE 反映的是模型的准确性, 其值越小, 则准确性越高; STD 反映的是模型的稳定性, 其值越小则稳定性越好。计算公式分别如下

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \tag{12}$$

$$MRE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \tag{13}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \tag{14}$$

$$STD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (e_i - \bar{e})^2} \quad i = 1, \dots, N \tag{15}$$

式中  $y_i$ 、 $\hat{y}_i$  分别为真实值和模型预测值,  $e_i = y_i - \hat{y}_i$ ,  $\bar{e} = \frac{1}{N} \sum_{i=1}^N e_i$ 。

通过表 3, 可以明显看到优化前后的 WLSSVM 模型对验证数据的预报效果差异, 经过免疫 PSO 算法优化后的 WLSSVM 预报模型对验证数据集的预报误差要明显小于初始 WLSSVM 预报模型, 其中纯 PSO 算法优化的模型预报结果介于中

间。平均绝对误差由初始 WLSSVM 预报模型的 0.0727 降为 0.0490, 降低了 32.6%; 平均相对误差由 2.76% 降为 1.86%, 降低了 32.6%; 均方根误差由 0.1172 降到 0.0905, 降低了 22.8%; 标准差由 0.1058 降到 0.0889, 降低了 15.97%。同时免疫 PSO 算法比纯 PSO 算法优化的模型效果更佳。

为了进一步验证模型的推广性, 表 4 给出了优化前后的 WLSSVM 预报模型对推广数据集的预报结果。从 4 个指标量同样可以看出, 优化后的模型比初始模型得到预报结果更加接近真实值, 而且免疫 PSO 比纯 PSO 算法优化效果要好。平均绝对误差由初始 WLSSVM 预报模型的 0.0742 降为 0.0358, 降低了 51.8%; 平均相对误差由 3.09% 降为 1.50%, 降低了 51.5%; 均方根误差由 0.0953 降到 0.0483, 降低了 49.3%; 标准差由 0.0985 降到 0.0494, 降低了 49.8%。

表 4 优化前后的 WLSSVM 预报模型对  
推广数据集的预报结果

Table 4 Prediction of LSSVM models before and after optimization on generalization dataset				
Model	MAE	MRE%	RMSE	STD
WLSSVM	0.0742	3.09	0.0953	0.0985
PSO_WLSSVM	0.0492	2.06	0.0643	0.0665
ICPSO_WLSSVM	0.0358	1.50	0.0483	0.0494

图 2 给出了优化前后 WLSSVM 模型对验证数据的预报结果。可以看到经过优化后的 WLSSVM 模型跟踪性能得到明显改善, 更加接近真实值。ICPSO 算法是在 PSO 算法的基础上, 加入了生成免疫粒子和基于粒子适应度的概率选择等过程, 保持了粒子的多样性, 所以更好地避免了 PSO 算法易陷于局部最优的问题。相对于 PSO 算法, ICP- SO 算法有较高的概率搜索到最优解。图 2(a) 也证明了 ICPSO \_ WLSSVM 模型比 PSO \_ WLSS- VM 算法的优化效果更佳, 预报值更加接近真实值, 预报误差更小。从推广数据集图 2(b) 来看, ICPSO \_ WLSSVM 模型的泛化能力最好, 预报值最接近真实值, 特别是 0~6 样点和 12~15 样点, 效果最明显。

3 结 论

为克服 PSO 算法的易陷于局部最优的缺陷, 本文利用免疫系统的免疫信息处理机制, 提出免疫粒子群算法 (ICPSO)。比较优化前后的 WLSSVM

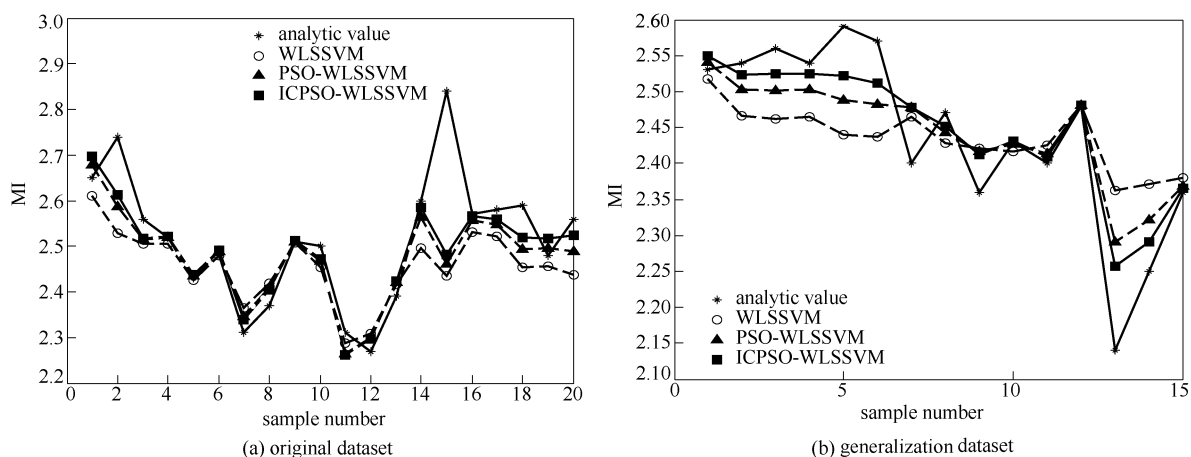


图2 优化前后 WLSSVM 模型对验证数据的预报结果

Fig. 2 Prediction of WLSSVM models before and after optimization on test dataset

模型, 说明了 ICPSO 优化算法提高了模型的预报精度和泛化能力。在验证数据集上, 与未优化的 WLSSVM 模型相比, 优化后的 ICPSO\_WLSSVM 模型的平均绝对误差降低了 32.6%, 平均相对误差降低了 32.6%, 均方根误差降低了 22.8%。同时与 Shi 等<sup>[8]</sup>的结果相比, 本文验证数据集和推广数据集的预报结果都提高很多, 其中验证数据集的平均相对误差从 2.49% 降到 1.86%, 降低了 25.3%, 平均绝对误差从 0.0635 降到 0.0490, 降低了 22.83%, 说明本文提出的模型预报结果更加准确。工业生产实例研究表明, ICPSO\_WLSSVM 方法建立的聚丙烯熔融指数预报模型具有有效性和可靠性, 对于聚丙烯生产的实际工业控制具有重要意义, 但在实际工业控制要求的高稳定性方面还需进一步研究。

## References

- [1] Bafna S S, Beall A M. A design of experiments study on the factors affecting variability in the melt index measurement [J]. *Journal of Applied Polymer Science*, 1997, **65** (2): 277-288
- [2] Cao Jin (曹劲), Wang Guizeng (王桂增), Xu Bowen (徐博文). Prediction of polypropylene melt index based on robust and adaptive RBF networks [J]. *Control and Decision* (控制与决策), 1999, **14** (4): 339-343
- [3] Li Chunfu (李春富), Wang Guizeng (王桂增), Xu Bowen (徐博文). Soft measurement of polypropylene MFR [J]. *Control and Instruments in Chemical Industry* (化工自动化及仪表), 2002, **29** (5): 22-25
- [4] Kong Wei (孔薇), Yang Jie (杨杰). Prediction of polypropylene melt index based on RBF neural networks [J]. *Journal of Chemical Industry and Engineering* (China) (化工学报), 2003, **54** (8): 1160-1163
- [5] Han I S, Han C H, Chung C B. Melt index modeling with support vector machines, partial least squares and artificial neural networks [J]. *Journal of Applied Polymer Science*, 2005, **95** (4): 967-974
- [6] Shi J, Liu X G, Sun Y X. Melt index prediction by neural networks based on independent component analysis and multi-scale analysis [J]. *Neurocomputing*, 2006, **70**: 280-287
- [7] Shi J, Liu X G. Melt index prediction by neural soft-sensor based on multi-scale analysis and principal component analysis [J]. *Chinese Journal of Chemical Engineering*, 2005, **13** (6): 849-852
- [8] Shi J, Liu X G. Melt index prediction by weighted least squares support vector machines [J]. *Journal of Applied Polymer Science*, 2006, **101** (1): 285-289
- [9] Zhang J, Jin Q B, Xu Y M. Inferential estimation of polymer melt index using sequentially trained bootstrap aggregated neural networks [J]. *Chemical Engineering and Technology*, 2006, **29** (4): 442-448
- [10] Vapnik V N. An overview of statistical learning theory [J]. *IEEE Transactions on Neural Networks*, 1999, **10** (5): 988-999
- [11] Suykens J A K, De Brabanter J, Lukas L, Vandewalle J. Weighted least squares support vector machines: robustness and sparse approximation [J]. *Neurocomputing*, 2002, **48**: 85-105
- [12] Chen Aijun (陈爱军), Song Zhihuan (宋执环), Li Ping (李平). Modeling method of least squares support vector regression based on vector base learning [J]. *Control Theory and Applications* (控制理论与应用), 2007, **24** (1): 1-5
- [13] Cao Wei (曹巍), Zhao Yingkai (赵英凯), Gao Shiwei (高世伟). Multi-class support vector machines based on fuzzy kernel cluster [J]. *CIESC Journal* (化工学报),

- 2010, **61** (2): 420-424
- [14] Suykens J A K, Vandewalle J. Least squares support vector machines classifiers [J]. *Neural Processing Letters*, 1999, **9** (3): 293-300
- [15] Suykens J A K, Vandewalle J. Recurrent least squares support vector machines [J]. *IEEE Transactions on Circuits and Systems*, 2000, **47** (7): 1109-1114
- [16] Niknam T, Mojarad H D, Meymand H Z. A novel hybrid particle swarm optimization for economic dispatch with valve-point loading effects [J]. *Energy Conversion and Management*, 2011, **52** (4): 1800-1809
- [17] Yang Fan (杨帆), Hu Chunping (胡春平), Yan Xuefeng (颜学峰). Particle swarm optimization algorithm of self-adaptive parameter based on ant system and its application [J]. *Control Theory and Applications* (控制理论与应用), 2010, **27** (11): 1479-1488
- [18] Zhou Yunlong (周云龙), Song Lianzhuang (宋连壮), Zhou Hongjuan (周红娟). Measurement of particle velocity in dilute phase based on PSO and Hopfield network matching [J]. *CIESC Journal* (化工学报), 2011, **62** (2): 348-354
- [19] Wang Lei (王磊), Pan Jin (潘进), Jiao Licheng (焦李成). The immune algorithm [J]. *Acta Electronic Sinica* (电子学报), 2000, **28** (7): 74-78