

优化岭参数的非线性岭回归及 4 - CBA 含量软测量

颜学峰

(华东理工大学 自动化研究所, 上海 200237)

摘 要:针对二甲苯氧化反应过程中影响主要副产物对羧基苯甲醛含量的因素众多且呈高度非线性问题,提出基于优化岭参数的非线性岭回归 MNRR 算法,并应用于建立 4-CBA 含量软测量模型,获得满意的结果. MNRR 采用非线性变换对原始模式特征空间进行扩张,以预测性能为指标,采用进化算法确定最佳岭参数,最终建立具有强非线性表达能力以及预测性能良好的模型. 与非线性最小二乘回归和基于广义交叉有效性逐步估计岭参数的非线性岭回归相比, MNRR 模型具有更高的预测精度且克服了传统岭回归算法最佳岭参数难以确定的缺点.

关键词:岭回归;岭参数;进化算法;软测量

中图分类号: O212.4 **文献标识码:** A **文章编号:** 1673-4785(2006)01-0074-05

Modified nonlinear ridge regression with optimal ridge parameter and its application to 4-CBA soft sensor

YAN Xue-feng

(Automation Institute, East China University of Science and Technology, Shanghai 200237, China)

Abstract: Considering that there exist many factors having high nonlinear and complex effect on the concentration of the 4-carboxybenzaldehyde (4-CBA) in product, which was the most important intermediate product of p-xylene oxidation reaction, a modified nonlinear ridge regression (MNRR) based on optimal ridge parameter, was proposed to develop the 4-CBA concentration soft sensor. Satisfactory results were obtained. Firstly, MNRR applied the nonlinear transformation for initial pattern independent variables to expand pattern space. Secondly, considering that there exists correlation or multicollinearity among the variables in the expanding pattern space, the ridge regression was employed, in which evolution algorithm was used to obtain the global optimal ridge parameter according to the predicting ability of the model. Thus, the model was obtained that can describe complex nonlinear system and has good predict accuracy. The comparison results show that the MNRR model has better predict accuracy than nonlinear least square regression and nonlinear ridge regression based on generalized cross-validation of selecting the ridge parameter. In addition, MNRR overcomes the main flaw in traditional ridge regression that is difficult to obtain the global optimal ridge parameter, and thus has the robust character.

Keywords: ridge regression; ridge parameter; evolution algorithm; soft sensor

在精对苯二甲酸(pure terephthalic acid, PTA)生产过程中^[1-4],对羧基苯甲醛(4-carboxybenzaldehyde, 4-CBA)是对二甲苯(p-xylene, PX)液相催化氧化反应产品对苯二甲酸(TA)的主要副产物. 目前,无合适在线仪表测定反应器中 4-CBA 含量,只

能采样分析,因此建立 TA 产品中 4-CBA 含量软测量,可以为生产操作条件及时调整提供指导. 软测量建模已提出了很多方法:如神经网络方法,具有强非线性表达能力,但易出现过拟合^[5-6];各种全局多元线性回归方法,建模速率高,特别是岭回归方法^[7-8],能处理自变量之间存在复共线关系,建立的模型鲁棒性强. 但岭回归算法难以描述高度非线性体系,以及最佳岭参数难以确定. 为此提出基于优化岭参数的非线性岭回归算法(modified nonlinear ridge

收稿日期:2006-01-24.

基金项目:国家自然科学基金资助项目(20506003);教育部科学技术研究重点基金资助项目(106073);上海科技启明星基金资助项目(04QMX1433).

regression, MNRR). MNRR 采用非线性变换对原始模式特征空间进行扩张, 实现在高维空间中能通过线性模型描述模式. 然后, 以预测性能为指标, 采用基于优选优生进化算法^[4,9] (select-best and prepotency evolution algorithm, SPEA) 确定最佳岭参数, 最终建立具有强非线性表达能力以及预测性能良好的模型. 将 MNRR 应用于建立 TA 中 4-CBA 含量软测量, 获得满意的结果.

1 影响 4-CBA 含量的因素分析

图 1 是 BP-AMOCO 工艺 PX 氧化反应流程图^[1-4]. 图中的混合进料包括新鲜 PX、新鲜醋酸 (HAc)、新鲜钴锰催化剂、新鲜溴促进剂、母固回收、氧化反应单元冷凝器部分凝液、高压吸收塔底洗涤液、循环母液进入配料混合罐, 混合成一定 PX 浓度的溶剂, 混合进料中的 PX 首先在氧化反应器中与空气中的氧气进行一次氧化, 以完成 PX 氧化反应的主要过程; 未完全氧化部分在第一结晶器中进行二次氧化; 第一结晶器的出料分别经过结晶单元的其他各结晶器、真空过滤机, 最后含 TA 滤饼经干燥机干燥成 (粗) TA 出装置.




图 1 PX 氧化反应流程图

Fig. 1 Flow chart of PX oxidation reaction process
由 PX 氧化反应机理^[1-3,10]和工业装置工艺流程分析, 在工业 PX 氧化反应过程中, 影响 TA 产品中 4-CBA 含量 (C_{4-CBA}) 的主要因素有: 混合进料中的钴催化剂浓度 (C_{Co}), 锰催化剂浓度 (C_{Mn}), 溴促进剂浓度 (C_{Br}), 反应温度 (T_{reactor}), 反应器抽出水流量 (mH₂O), 氧化反应器停留时间 (t_{reactor}), 第一结晶器温度 (T_{crystal}), 第一结晶器停留时间 (t_{crystal}) 等因素. 这些影响因素值均可以实时通过装置中控室的 DCS 系统直接 (或间接计算) 获得.

2 优化岭参数的非线性岭回归

2.1 岭回归分析

设模式的自变量向量 x 维数为 p , 模式的因变

量为 y , 样本容量为 n , 则结构矩阵或设计矩阵 X 为

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix}. \quad (1)$$

多元线性回归模型为

$$y = X\beta + \varepsilon. \quad (2)$$

式中: $y = [y_1 \ y_2 \ \dots \ y_n]^T$ 是因变量向量; $\beta = [\beta_0 \ \beta_1 \ \beta_2 \ \dots \ \beta_p]^T$ 是参数向量; $\varepsilon = [\varepsilon_1 \ \varepsilon_2 \ \dots \ \varepsilon_n]^T$ 是 n 维正态随机残差向量, 它的均向量为 n 维零向量 $0 = [0 \ 0 \ \dots \ 0]^T$, 它的协方差矩阵为 n 维等对角矩阵 $\sigma^2 I$, 可记为 $N(0, \sigma^2 I)$.

采用最小二乘估计, 其估计值称为最小二乘估计, 记为 $\hat{\beta} = [\hat{\beta}_0 \ \hat{\beta}_1 \ \dots \ \hat{\beta}_p]^T$, 则 $\hat{\beta}$ 所满足的正规方程组为 $(X^T X) \hat{\beta} = X^T y$, 解得

$$\hat{\beta} = (X^T X)^{-1} X^T y. \quad (3)$$

对回归系数进行统计性质分析可以得出: $\hat{\beta}$ 是无偏估计^[12]. 对 $\hat{\beta}$ 的均方误差分析^[12]可以得到

$$\sigma_{\hat{\beta}}^2 = E[(\hat{\beta} - \beta)(\hat{\beta} - \beta)^T] = \sigma^2 \sum_{i=1}^{p+1} \frac{1}{\lambda_i}. \quad (4)$$

式中: $\lambda_1 \ \lambda_2 \ \dots \ \lambda_{p+1} > 0$ 是非负定的实对称信息矩阵 $A = X^T X$ 的 $p+1$ 个特征根. 因此, 当 A 接近于奇异, 亦即各自变量之间存在复共线关系时, 一些特征根接近于 0, $\frac{1}{\lambda_i}$ 将变得很大, 从而使 $\sigma_{\hat{\beta}}^2$ 的值也非常之大. 这说明估计值 $\hat{\beta}$ 与参数值可能相距甚远, 二者之间有较大的偏差.

针对复共线关系问题, Hoerl 和 Kennard^[7] 提出的岭回归算法. 岭回归在最小二乘的基础上引入了岭参数 k , 用 $X^T X + kI$ 来替代原来的 $X^T X$, 这样矩阵 $X^T X + kI$ 的特征根为: $\lambda_1 + k, \lambda_2 + k, \dots, \lambda_{p+1} + k$. 则 $X^T X + kI$ 矩阵对应的特征根就离开 0 远一些, 使 $\hat{\beta}$ 的均方误差减小, 且一定存在一个最优的岭参数 k 使式 (4) 达到最小. 用岭回归方法估计可表示为

$$\hat{\beta}_k = (X^T X + kI)^{-1} X^T y. \quad (5)$$

式中: I 表示单位矩阵.

用岭回归方法解决复共线问题的关键就在于确定岭参数 k , 确定岭参数 k 的方法有岭迹法、公式法、基于广义交叉有效性 (generalized cross validation, GCV) 的逐步估计求值法等^[11]. 其中 GCV 法获得比较广泛的应用, 但 GCV 法存在初始岭参数难以确定且最终确定值严重依赖初始值的不足.

2.2 SPEA 优化岭参数的岭回归算法

由于最优的岭参数 k 值可以确定最佳岭回归模型,而预测性能是模型最重要的性能指标,为此,提出以岭回归模型预测性能为指标,基于 SPEA 优化确定岭参数的岭回归算法。其中 SPEA 以实数编码、线性交叉的遗传算法^[12]为基础,主要操作步骤有:优选优生操作、变异操作。SPEA 计算复杂性低,局部搜索能力和全局寻优能力强,在复杂模式识别^[10]和模型参数确定^[4]等领域都得到成功的应用。

2.2.1 优选优生进化算法

在实数编码的遗传算法中^[12],每个优化参数被当做一个位基因直接处理,设优化参数为 o_1, o_2, \dots, o_l 共 l 个,则个体可以用 l 维矢量 $O = [o_1 \ o_2 \ \dots \ o_l]$ 表示。对于第 i 位基因,其相应的线性交叉操作作为

$$\begin{cases} u_i^{(1)} = i * o_i^{(1)} + (1 - i) * o_i^{(2)}, 0 < i < 1, \\ u_i^{(2)} = i * o_i^{(2)} + (1 - i) * o_i^{(1)}, i = 1, 2, \dots, l. \end{cases} \quad (6)$$

式中: i 是随机数, $o_i^{(1)}$ 、 $o_i^{(2)}$ 是 2 个父代个体的第 i 位基因, $u_i^{(1)}$ 、 $u_i^{(2)}$ 是它们的 2 个子代个体的第 i 位基因。设群体 P 的规模为 N_P ,其所有个体记为 o_1, o_2, \dots, o_{N_P} ,交叉概率为 v_c ,优选邻域大小为 m ,优化问题表述为

$$\min f(o_1, o_2, \dots, o_l) \quad a_i \leq o_i \leq b_i \quad (7)$$

式中: $i = 1, 2, \dots, l$ 是 o_i 的上下限, $\{ (a_i, b_i), i = 1, 2, \dots, l \}$ 构成了 l 维优化参数定义空间 S_0 。

则针对 N_P 个个体执行如下优选优生操作:

- 1) 设新群体初始个数 $n_p = 0$, 中间变量 $i = 1$ 。
- 2) 产生 $(0, 1)$ 随机数 v , 若 $v > v_c$, 则 $i = 1$, $i = N_P$, 重新执行 2); 若 $v \leq v_c$, 则挑选第 i 个个体 o_i 进行以下操作。
 - 3) 设 o_i 的优选邻域所有个体组成群体为 $S_{o_i} = \begin{cases} \{ o_{i+1}, o_{i+1}, \dots, o_{i+m} \} & i + m \leq N_P \\ \{ o_{i+1}, o_{i+2}, \dots, o_{N_P}, o_1, \dots, o_{m-(N_P-i)} \} & i + m > N_P \end{cases}$
 - 4) 挑选 S_{o_i} 中最优个体 o_i^{opt} 。
 - 5) 对 o_i 和 o_i^{opt} 执行式(6),产生子代个体 u_i^1 和 u_i^2 。
 - 6) 保留 u_i^1 和 u_i^2 中较优的子代个体作为新群体中第 $j = n_p + 1$ 个个体 n_{o_j} , 且 $n_p = n_p + 1, i = i + 1, i < N_P$ 。
- 7) 若 $n_p < N_P$, 返回步骤 2); 若 $n_p = N_P$, 产生新

群体 $N_0 = \{ n_{o_1}, n_{o_2}, \dots, n_{o_{N_P}} \}$, 结束。

优选优生进化算法的执行步骤:

- 1) 初始化。产生第 $g_n = 1$ 代 N_P 个初始个体 o_1, o_2, \dots, o_{N_P} , 记为 $O_{g_n}^{(1)} = [o_1, o_2, \dots, o_{N_P}]$ 。
- 2) 对 $O_{g_n}^{(1)}$ 执行优选优生操作, 产生新群体 $O_{g_n}^{(2)}$ 。
- 3) 对 $O_{g_n}^{(2)}$ 执行变异操作, 产生下一代群体 $O_{g_n}^{(3)}$ 。
- 4) 检查结束条件, 若已满足, 则终止计算; 否则, $g_n = g_n + 1, O_{g_n-1}^{(1)} = O_{g_n-1}^{(3)}$, 并转到步骤 2)。

2.2.2 岭回归的优化目标函数

设建模样本容量为 n , 对应的结构矩阵 X 为 $n \times (p+1)$ 维, 对应的因变量向量 y 为 $n \times 1$ 维; 校验样本容量为 n_t , 对应的结构矩阵 X_t 为 $n_t \times (p+1)$ 维, 对应的因变量向量 y_t 为 $n_t \times 1$ 维。则对于给定岭参数 k , RR 模型对校验样本的预测偏差平方和均值 MSE_k 为

$$MSE_k = \frac{1}{n_t} (y_t - \hat{y}_t)^T (y_t - \hat{y}_t), \quad (8)$$

式中: \hat{y}_t 是 RR 模型对 y_t 的预测值, 即

$$\hat{y}_t = X_t^T \hat{\beta}_k,$$

$$\hat{\beta}_k = (X^T X + kI)^{-1} X^T y. \quad (9)$$

由式(8)、(9)可知, MSE_k 是岭参数 k 的函数。因此基于 SPEA 优化岭参数 k 的岭回归算法以岭参数 k 为优化变量, 以 MSE_k 最小为优化目标函数 (即 $\min_k MSE_k$), 采用 SPEA 寻求使 MSE_k 最小 (设为 $MSE_{k_{\text{opt}}}$) 的岭参数 k (设为 k_{opt}), 即建立最优的 RR 模型。

2.3 非线性岭回归算法

岭回归算法很好地解决了自变量之间复共线关系的影响, 但无法描述呈高度非线性特征的过程对象, 为此, 提出对原始模式特征空间进行扩张, 使扩张后的特征空间对模式的表达获得增强, 实现在高维空间 (即扩张后的特征空间) 中通过线性模型描述模式对象。

原始模式自变量的扩张可以采用各种方法, 如对自变量可以简单地展开成它的幂函数, 或展开成维空间的正交基函数的 1 个子集等, 然后将原始模式自变量与展开变量组合成新的自变量 (即扩张后的特征空间中的自变量)。文中采用如下方便可行的阶扩张算法, 对于原始模式自变量 $x_i (i = 1, 2, \dots, p)$ 经 w 阶扩张后新的自变量为

$$\{ x_{i_1}, x_{i_1} x_{i_2}, \dots, x_{i_1} x_{i_2} \dots x_{i_w} \} / i_1 = 1, 2, \dots, p, i_2 \dots i_w \}, \quad (10)$$

则基于优化岭参数的非线性岭回归首先采用式(10)实现对原始模式特征空间的扩张, 形成新的自变量;

然后,针对由新自变量构成的结构矩阵和因变量向量,以式(8)最小为目标函数,通过 SPEA 寻求最优岭参数 k_{opt} ,建立具有强非线性表达能力且预测性能良好的 MNRR 模型.

3 基于 MNRR 的 4-CBA 含量软测量

3.1 试验设计

将以上分析的影响 TA 中 4-CBA 含量 C_{4-CBA} 的 8 个主要因素 (C_{CO} 、 C_{Mn} 、 C_{Br} 、 $T_{reactor}$ 、 m_{H_2O} 、 $reactor$ 、 $T_{crystal}$ 、 $crystal$) 作为软测量的自变量,TA 中 4-CBA 含量 C_{4-CBA} 作为因变量.采集到 197 个具有代表性的样本数据,随机选取其中 132 个样本作为建模样本数据 S ,剩余 65 个样本作为校验样本数据 S_T .为了分析 MNRR 模型的性能,设计如下 3 个试验:

试验 1:分别采用基于 SPEA 优化岭参数的岭回归算法(MRR)和基于 SPEA 优化岭参数的非线性岭回归算法(MNRR)建立 TA 中 4-CBA 含量软测量模型,其中 MNRR 的原始模式自变量的扩张阶数为 2,优化变量(岭参数)的上下限为(0,10).

试验 2:分别采用基于广义交叉有效性(GCV)逐步估计岭参数的岭回归算法(GRR)和基于 GCV 非线性岭回归算法(GNRR)建立 TA 中 4-CBA 含量软测量模型,其中 GNRR 的原始模式自变量的扩张阶数为 2,岭参数的初始值设为 1.

试验 3:分别采用最小二乘回归算法(LSR)和非线性最小二乘回归算法(NLSR)建立 TA 中 4-CBA 含量软测量模型,其中 NLSR 的原始模式自变量的扩张阶数为 2.

3.2 试验结果及分析

试验 1、2、3 中各算法建立的 4-CBA 含量软测量模型对建模样本的拟合偏差平方和均值 MSE 和对校验样本的预测偏差平方和均值 MSE 的结果如表 1 所示.从表 1 的各模型预测精度可以看出,MNRR 模型具有最佳的预测性能,MNRR 模型预测偏差平方和均值比线性模型(MRR 或 GRR)降低了 26.4%,比次优的 GNRR 模型降低了 9.8%.因此,MNRR 具有强非线性表达能力,算法能以对校验样本的预测偏差平方和均值最小为目标,通过 SPEA 寻求全局最佳的岭参数,获得最佳模型.同时,MRR 模型和 GRR 模型预测精度均高于 LSR 模型;MNRR 模型和 GNRR 模型预测精度均高于 NLSR 模型.可见,原始模式自变量之间和扩张后新的自变量之间存在一定的复共线关系,采用岭回归算法可以消除复共线关系影响,建立预测性能良好的模型.

表 1 试验结果					
Table 1		Trial results		$\times 10^{-4}$	
线性	预测	拟合	非线性	预测	拟合
算法	MSE	MSE	算法	MSE	MSE
MRR	2.5	2.43	MNRR	1.84	1.35
GRR	2.5	2.42	GNRR	2.04	1.74
LSR	2.54	2.41	NLSR	2.59	1.17

从表 1 的各模型拟合精度可以看出,LSR 在线性模型中具有最好的拟合精度,但预测精度最低;NLSR 在非线形模型中也具有最好的拟合精度,但预测精度也最低;NLSR 模型的拟合精度甚至高于 LSR 模型,但 NLSR 模型的预测精度却低于 LSR 模型,可见 LSR 和 NLSR 模型均已出现不同程度的过拟合现象.在线性模型中,MRR 和 GRR 模型具有近似相同的拟合精度和预测精度;在非线形模型中,MNRR 模型的拟合精度和预测精度均高于 GNRR 模型,这是因为 MNRR 算法寻求的是全局最优岭参数,在试验 1 中寻得最优岭参数 $k_{opt} = 1.37 \times 10^{-6}$;而 GNRR 基于梯度算法的逐步迭代易陷入局部解且最终结果严重依赖岭参数初始值的选取,在试验 2 中寻得岭参数 $k = 7.9 \times 10^{-3}$,从表 1 的结果以及以下进一步分析结果可以看出 $k = 7.9 \times 10^{-3}$ 是局部最优解.

为了进一步对比 MNRR 与 GNRR 算法,分别取 GNRR 的初始岭参数为 8 个值,则 GNRR 算法最终求得的岭参数分别为 1 、 1×10^{-1} 、 1×10^{-2} 、 1×10^{-3} 、 1×10^{-4} 、 1×10^{-5} 、 1×10^{-6} 、 1×10^{-7} 等 8 个值,则 GNRR 算法最终求得的岭参数分别为: 7.9×10^{-3} 、 7.9×10^{-3} 、 7.9×10^{-3} 、 7.9×10^{-3} 、 7.9×10^{-3} 、 7.9×10^{-3} 、 1.47×10^{-6} 、 1.47×10^{-6} ,其中前 6 个相同是局部最优解,后 2 个相同是全局最优解(由于 GCV 法是基于建模样本 S 采用留一交叉验证法,而基于 SPEA 优化岭参数法是基于建模样本 S ,以对校验样本 S_T 预测偏差平方和最小为目标确定岭参数,因此,2 种方法求得各自全局最优解将略有差异),其全局最优解对校验样本的预测偏差平方和均值 MSE 为 0.000184.可见,对于 GNRR 算法,当初始岭参数 $k = 1 \times 10^{-5}$ 时,陷入局部最优解;当初始岭参数 $1 \times 10^{-6} < k > 0$ 时,才可以求得全局最优解,而确定如此小的初始值选取范围无疑是非常困难的,而且不同性质的问题(即不同程度的复共线问题)具有不同的初始值选取范围.岭回归的其他确定岭参数算法也存在类似的缺点.MNRR 算法在岭

参数的上下限为(0,10)内寻得全局最优解 $k_{opt} = 1.37 \times 10^{-6}$,且理论上只要确定的寻优范围包含全局最优解,MNRR算法就可以寻得全局最优解,因此MNRR算法具有强鲁棒性。

为了直观说明建立的MNRR软测量模型的性能,以TA产品中4-CBA含量分析值为横坐标,以4-CBA软测量模型对校验样本的预测值为纵坐标作图,结果如图2所示。可以看出,图中方形点分布在直线的两侧(若方形点落在直线上,则预测值与分析值相同),模型能良好预测TA产品中4-CBA含量。




图2 MNRR预测性能

Fig. 2 Prediction ionaccuracy of MNRR

4 结束语

基于优化岭参数的非线性岭回归(MNRR)算法,首先采用阶扩张算法实现对原始模式特征空间的扩张,使扩张后的特征空间对模式的表达获得增强。然后,针对扩张后新自变量之间可能存在的复共线关系以及岭回归算法中最佳岭参数难以确定的缺点,提出基于优选优进化算法确定最佳岭参数的岭回归算法,消除变量间的复共线关系影响,最终建立具有强非线性表达能力以及预测性能良好的MNRR模型。在实际应用于建立TA中4-CBA含量软测量,获得满意的结果。与非线性最小二乘回归和基于广义交叉有效性逐步估计岭参数的非线性岭回归相比,基于优化岭参数的非线性岭回归模型具有更高的预测精度,且克服传统岭回归算法中最佳岭参数难以确定的缺点。

参考文献:

- [1] YAN X F, DU W L, QIAN F. Development of a kinetic model for industrial oxidation of p-Xylene by RBF-PLS and CGA[J]. AIChE Journal, 2004, 50(6): 1169 - 1176.
- [2] PRENGLE J H W, BAROND N. Make petrochemicals by liquid phase oxidation[J]. Hydrocarbon Process, 1970, 49(3): 106 - 118.

- [3] RAGHAVENDRACHAR P, RAMACHANDRAN S. Liquid-phase catalytic oxidation of p-Xylene [J]. Ind Eng Chem Res, 1992, 31(2): 453 - 462.
- [4] 颜学峰, 余娟, 钱锋. 优选优进化算法及4-CBA软测量模型参数估计[J]. 高校化学工程学报, 2005, 19(2): 238 - 243.
- [5] YAN Xuefeng, YU Juan, QIAN Feng. An evolution algorithm with select-best and prepotency operator and parameter estimation of 4-CBA model [J]. Journal of Chemical Engineering of Chinese Universities, 2005, 19(2): 238 - 243.
- [5] 何永勇, 褚福磊, 种秉林. 基于进化计算的神经网络设计与实现[J]. 控制与决策, 2001, 16(3): 257 - 262.
- HE Yongyong, CHU Fulei, ZHONG Binglin. Artificial neural networks design and implementation based on evolutionary computation [J]. Control and Decision, 2001, 16(3): 257 - 262.
- [6] 赵启林, 陈斌, 卓家寿. 前馈神经网络结构自删除算法的研究[J]. 河海大学学报, 2000, 28(4): 63 - 66.
- ZHAO Qilin, CHEN Bin, ZHUO Jiashou. Self-deleting algorithm of feedforward neural networks [J]. Journal of Hehai University, 2000, 28(4): 63 - 66.
- [7] 杨楠. 岭回归分析在解决多重共线性问题中的独特作用[J]. 统计与决策, 2004(3): 14 - 15.
- YANG Nan. Role of ridge regression to solve multilinear problem [J]. Statistics and Decision, 2004(3): 14 - 15.
- [8] GAVIN C, CAWLEY A, NICOLA L C T, ROBERT J F, et al. Heteroscedastic kernel ridge regression [J]. Neurocomputing, 2004, 57(1): 105 - 124.
- [9] YAN X F, YU J, QIAN F. The feature-preserving map of high-dimensional complex chemical objects using non-linear map Integrated with correlative component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 2005, 75(1): 13 - 22.
- [10] 孙静民. 聚酯工艺[M]. 北京: 化学工业出版社, 1985.
- SUN Jingmin. Polyester technics [M]. Beijing: Chemical Industry Press, 1985.
- [11] 胡上序, 陈德钊. 观测数据的分析与处理[M]. 杭州: 浙江大学出版社, 1996.
- HU Shangxu, CHEN Dezhaohao. Observed data analysis and processing [M]. Hangzhou: Zhejiang University Press, 1996.
- [12] MICHAŁ EWICZ Z. Genetic algorithms + data structures = evolution programs[M]. Berlin: Springer-Verlag, 1992.

作者简介:



颜学峰, 副研究员, 2002年6月获浙江大学控制理论与控制工程博士学位。主要研究方向: 复杂系统建模与优化、智能信息处理。在国内外核心期刊上发表30余篇相关论文(其中10余篇已被SCI、EI收录), 曾获国家科技进步二等奖1项、省部级科技进步奖多项。

E-mail: xfyan@ecust.edu.cn