

文章编号: 1001-0920(2005)10-1102-05

## 基于 ISVM 的软测量建模及其在 PX 生产中的应用研究

张英<sup>a,b</sup>, 苏宏业<sup>a,b</sup>, 褚健<sup>a,b</sup>

(浙江大学 a 工业控制技术国家重点实验室, b 先进控制研究所, 杭州 310027)

**摘要:** 针对软测量模型存在的失效问题, 提出一种基于增量支持向量机的建模方法。随着时间的推移, 每次在模型中增加一个样本进行增量学习的同时, 采用启发式策略去掉工作集中一个老的样本, 从而可以在软测量模型中不断增加能够代表新工况信息样本的同时控制工作样本集的规模。将所提出的软测量建模方法用于二甲苯(PX)吸附分离过程纯度的预测, 结果表明所提出的建模方法以及样本替换策略可以有效地增强软测量模型适应工况变化的能力, 提高其预测的精度。

**关键词:** 支持向量机; 增量学习; 软测量; PX 吸附分离过程

中图分类号: TP274

文献标识码: A

## Soft Sensor Modeling Based on ISVM and Its Application in PX Fractionation

ZHANG Ying<sup>a,b</sup>, SU Hong-yue<sup>a,b</sup>, CHU Jian<sup>a,b</sup>

(a National Laboratory of Industrial Control Technology, b Institute of Advanced Process Control, Zhejiang University, Hangzhou 310027, China. Correspondent: ZHANG Ying, E-mail: zhangying@ipc.zju.edu.cn)

**Abstract:** In order to overcome model failure problem, a soft sensor modeling method based on incremental support vector machines (ISVM) is presented. In ISVM, an incremental sample which represents new operational condition is introduced to the model, whereas an old sample is discarded from the model to control the size of working set. The proposed method is applied to predict the purity of para-xylene (PX) in a PX fractionation by adsorption process. Simulation results show that the proposed soft sensor model actually increases the adaptive abilities to various operation conditions and solves the model failure problem caused by change of operation conditions or load.

**Key words:** Support vector machines; Incremental learning; Soft sensor; Para-xylene fractionation by adsorption process

### 1 引言

随着我国聚酯行业的迅速发展, 国内对二甲苯(PX)的需求量急剧增加。目前采用模拟移动床吸附分离方法从混合二甲苯中分离 PX 是生产 PX 的主要途径<sup>[1]</sup>。以某炼油厂 PX 装置为例, 吸附分离部分由两个串联的吸附塔组成, 每个塔中的床层通过集合管与进料、解吸剂、抽出液、抽余液和反洗液 5 股物料相连。当含有 4 种 C<sub>8</sub> 芳烃同分异构体的混合二甲苯进入吸附塔后, 由于吸附剂对 4 种 C<sub>8</sub> 芳烃吸附强度的差异, 吸附能力较强的二甲苯会缓慢地从吸

剂中脱附出来, 将其作为抽出液, 经过提纯后可以得到高纯度的 PX<sup>[2]</sup>。其原理如图 1 所示。




图 1 模拟移动床 PX 吸附分离原理示意图

收稿日期: 2004-11-03; 修回日期: 2005-03-03

基金项目: 国家杰出青年科学基金项目(NO YSFC, 60025308); 浙江省“151”人才重点项目。

作者简介: 张英(1975-), 男, 湖北天门人, 博士生, 从事数据挖掘、机器学习等研究; 苏宏业(1969-), 男, 杭州人, 教授, 博士生导师, 从事先进控制理论与应用等研究。

在工业生产中, PX 纯度离线分析通常滞后数小时, 远远不能满足控制的要求, 为了实时预测产品的纯度, 通常采用的方法是建立软测量模型。软测量模型在现场运行后, 随着时间的推移往往会出现模型老化现象, 这主要是由于工业过程所具有的慢时变特性造成的<sup>[3]</sup>。这时需要采取一些方法对模型进行维护, 最直接的方法是利用新采集的数据重新建立模型。但这样会抛弃历史的训练结果, 如果收集到的训练样本并没有均匀分布在操作区间内, 所建立的软测量模型将是一个局部模型。

近年来, Vapnik 提出了以有限样本统计学习理论为基础的支持向量机<sup>[4]</sup>(SVM), 通过解决一个二次规划来求取样本的最优分类面。由于 SVM 有效地解决了非线性、过学习等一系列难题, 使得它受到广泛的关注<sup>[5]</sup>。本文提出一种基于增量支持向量机 (ISVM) 的建模方法来解决软测量模型中的失效问题, 并将所提出的方法用于 PX 吸附分离过程中纯度的预测, 所得结果验证了本文方法的有效性。

## 2 支持向量回归

Vapnik 在定义了  $\epsilon$  不敏感损失函数的基础上, 提出了支持向量回归算法 SVR<sup>[4]</sup>。给定  $l$  个独立同分布的数据样本组成的集合

$$X = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_l, y_l)\},$$

$$x_i \in \mathbb{R}^n, i = 1, \dots, l$$

寻求一个最优函数  $f(x) = (w \cdot x) + b, w, b \in \mathbb{R}$ , 使得预测的期望风险最小<sup>[4]</sup>。

$$\begin{aligned} \max W = & \\ & - \epsilon \sum_{i=1}^l (\alpha + \alpha^*) + \sum_{i=1}^l (\alpha - \alpha^*) y_i - \\ & \frac{1}{2} \sum_{i,j=1}^l (\alpha - \alpha^*) (\alpha_j - \alpha_j^*) (x_i \cdot x_j). \end{aligned}$$

$$\text{s.t.} \begin{cases} (\alpha - \alpha^*) = 0, \\ 0 \leq \alpha, \alpha^* \leq C, i = 1, \dots, l \end{cases} \quad (1)$$

在非线性的情况下, 引入变换  $\mathcal{Q}: \mathbb{R}^n \rightarrow \mathbb{H}$ , 将样本从输入空间  $\mathbb{R}^n$  映射到一个高维特征空间  $\mathbb{H}$ ; 然后在  $\mathbb{H}$  中求取最优函数, 使得预先定义的风险函数最小。根据 Mercer 条件<sup>[8]</sup>, 存在核函数  $K(\cdot, \cdot)$ , 使得  $K(x_i, x_j) = \mathcal{Q}(x_i) \cdot \mathcal{Q}(x_j)$ , 引入核函数后回归函数为

$$f(x) = \sum_{i=1}^l (\alpha - \alpha^*) K(x_i, x) + b \quad (2)$$

## 3 基于 ISVM 的软测量建模

定义集合  $X_{\text{nbSV}} = \{(x_i, y_i) \mid 0 < \alpha, \alpha^* < C\}$ ,  $X_{\text{nsV}} = \{(x_i, y_i) \mid \alpha, \alpha^* = 0\}$  和  $X_{\text{bsV}} = \{(x_i, y_i) \mid \alpha, \alpha^* = C\}$  分别为非边界支持向量、非支持向量和边界支持向量的集合。由于  $K(x_i, x_j)$  为半正定, 且式(1)中所

有的等式约束为线性的, 根据 KKT 条件<sup>[9]</sup>可得到:

$$g_i^{(*)} = \begin{cases} |y_i - f(x_i)| - \epsilon < 0, \alpha, \alpha^* = 0, \\ (x_i, y_i) \in X_{\text{nsV}}; \\ |y_i - f(x_i)| - \epsilon = 0, 0 < \alpha, \alpha^* < C, \\ (x_i, y_i) \in X_{\text{nbSV}}; \\ |y_i - f(x_i)| - \epsilon > 0, \alpha, \alpha^* = C, \\ (x_i, y_i) \in X_{\text{bsV}}. \end{cases} \quad (3)$$

$$\sum_{i=1}^l (\alpha - \alpha^*) = 0, \alpha, \alpha^* \in [0, C]$$

从式(3)可以看出, 如果样本满足 KKT 条件, 则  $g_i^{(*)} < 0$ , 表明样本位于回归间隔线之间, 这些样本加入工作集后, 不会改变回归函数。只有当  $g_i^{(*)} = 0$  时, 即增量样本不满足 KKT 条件时, 才进行增量学习步骤。

### 3.1 增量支持向量机

最近, Cauwenberghs 和 Poggio 通过分析加入增量样本后 KKT 条件的变化, 提出了增量支持向量机的概念<sup>[7]</sup>。当增量样本  $(x_c, y_c)$  加入工作样本集后, KKT 条件的微分可写为

$$\begin{aligned} \Delta g_i = & K(x_i, x_c) \Delta(\alpha - \alpha^*) + \\ & K(x_i, x_j) \Delta(\alpha_j - \alpha_j^*) + \Delta b, \\ \Delta g_i^* = & - K(x_i, x_c) \Delta(\alpha - \alpha^*) - \\ & K(x_i, x_j) \Delta(\alpha_j - \alpha_j^*) - \Delta b, \\ \Delta(\alpha - \alpha^*) + & \sum_{(x_j, y_j) \in X_{\text{nbSV}}} \Delta(\alpha_j - \alpha_j^*) = 0 \end{aligned} \quad (4)$$

定义  $\mathcal{Y}_j = \alpha_j - \alpha_j^*$ , 对于非边界支持向量集  $X_{\text{nbSV}} = \{(x_{s_1}, y_{s_1}), \dots, (x_{s_n}, y_{s_n})\}$ , 有  $g_i^{(*)} = 0$ , 进而得到  $\Delta g_i^{(*)} = 0 \mid (x_i, y_i) \in X_{\text{nbSV}}$ 。假设使用的核函数为高斯核, 根据式(4)得到如下矩阵方程<sup>[6,7]</sup>:

$$Q \cdot \begin{bmatrix} \Delta b \\ \Delta \mathcal{Y}_{s_1} \\ \vdots \\ \Delta \mathcal{Y}_{s_n} \end{bmatrix} = - \begin{bmatrix} 1 \\ K(x_{s_1}, x_c) \\ \vdots \\ K(x_{s_n}, x_c) \end{bmatrix} \Delta \mathcal{Y}_c, \quad (5)$$

其中

$$Q = \begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_{s_1}, x_{s_1}) & \dots & K(x_{s_1}, x_{s_n}) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & K(x_{s_n}, x_{s_1}) & \dots & K(x_{s_n}, x_{s_n}) \end{bmatrix} \quad (6)$$

式中  $x_{s_j}$  代表第  $j$  个非边界支持向量,  $j = 1, \dots, n$ ,  $n$  为非边界支持向量个数。定义敏感系数  $\beta = \Delta b / \Delta \mathcal{Y}_c$ ,  $\dots, \beta_j = \Delta \mathcal{Y}_j / \Delta \mathcal{Y}_c, \dots, \beta_{s_n} = \Delta \mathcal{Y}_{s_n} / \Delta \mathcal{Y}_c, j = 1, \dots, s_n$ , 令

$R = Q^{-1}$  得到

$$\begin{bmatrix} \beta \\ \beta_{s_1} \\ \vdots \\ \beta_{s_n} \end{bmatrix} = -R \begin{bmatrix} 1 \\ K(x_{s_1}, x_{s_c}) \\ \vdots \\ K(x_{s_n}, x_{s_c}) \end{bmatrix} \quad (7)$$

对于每个样本

$$\Delta g_i^{(*)} = \begin{cases} \pm \Delta y_c \pi_i, & (x_i, y_i) \notin X_{\text{nbvs}}; \\ 0, & (x_i, y_i) \in X_{\text{nbvs}}; \\ i = 1, \dots, l+1 \end{cases} \quad (8)$$

其中  $\pi_i = K(x_i, x_c) + \sum_{(x_j, y_j) \in X_{\text{nbvs}}} K(x_i, x_j) \beta_j + \beta$  当新的样本  $(x_c, y_c)$  加入到  $X_{\text{nbvs}}$  时, 矩阵  $R$  更新为

$$R \begin{bmatrix} & & & 0 \\ & R & & \vdots \\ & & & 0 \\ 0 & \dots & 0 & 0 \end{bmatrix} + \frac{1}{\pi_c} \begin{bmatrix} \beta \\ \beta_{s_1} \\ \vdots \\ \beta_{s_n} \\ 1 \end{bmatrix} [\beta \ \beta_{s_1} \ \dots \ \beta_{s_n} \ 1] \quad (9)$$

综上所述, 当新的样本  $(x_c, y_c)$  加入到  $X_{\text{nbvs}}$  时, 首先根据当前的矩阵  $R$  计算矩阵 (8); 然后根据式 (4) 和 (8) 重新分配集合  $X_{\text{bvs}}, X_{\text{nsvs}}, X_{\text{nbvs}}$  中元素, 当一个支持向量加入时, 根据式 (9) 更新矩阵  $R$ .

### 3.2 启发式替换策略

采用增量支持向量机方法, 可以在每收集到一个训练样本后, 在原有学习的基础上进行增量学习, 而不需要重新训练整个样本集. 但直接将增量支持向量机用于软测量建模存在一个问题, 随着时间的推移, 支持向量的数量必然会变得十分庞大, 存储和更新  $R$  会变得很困难, 因此需要控制支持向量集的规模. 可以考虑在新增加一个支持向量的同时, 将工作集中一个不太重要的支持向量剔除, 保持学习过程中支持向量数量的固定. 剔除支持向量最直接的方法是随机选取一个支持向量将其剔除, 但不同的支持向量, 其对回归函数的贡献程度不同, 这样作带有一定的盲目性. 本文采用两种启发式策略剔除工作样本集中的支持向量.

#### 1) 基于时间的策略

由于工业过程的慢时变特性, 随着时间的推移, 最近采集的样本要比最早采集的样本更能反应当前的工况. 因此, 可以考虑在增加一个支持向量的同时, 剔除一个最早采集的样本 (支持向量).

假设工作样本集中支持向量序列为  $\{(x_{t_1}, y_{t_1}), \dots, (x_{t_l}, y_{t_l}), \dots, (x_{t_n}, y_{t_n})\}$ , 其中  $n$  代表支持向量个数,

$t_1 \dots t_l \dots t_n$  为样本采集的时间序列. 当增量样本  $(x_c, y_c)$  加入工作样本集时, 考虑将最先采集的样本 (支持向量)  $(x_{t_1}, y_{t_1})$  从工作样本集中剔除.

#### 2) 基于支持向量数据域描述的策略

支持向量数据域描述 (SVDD) 的方法可描述为: 输入空间中的数据样本被映射到一个高维的特征空间; 然后在这个空间中寻找样本的最小包含超球<sup>[10]</sup>.

$$\begin{aligned} \max Q(\beta) = & \sum_{i=1}^l K(x_i, x_i) \beta_i - \sum_{i,j=1}^l \beta_i \beta_j K(x_i, x_j) \\ \text{s.t. } & 0 \leq \beta_i \leq C, i = 1, 2, \dots, l \end{aligned} \quad (10)$$

求解上述规划问题, 可得到特征空间中的超球半径  $R$  以及点到超球球心的距离  $D(x_i)$ . 特征空间中的样本到超球球心的距离  $D(x_i)$  可根据如下等式得到<sup>[11]</sup>:

$$D^2(x_i) = \sum_{i,j=1}^l \beta_i \beta_j K(x_i, x_j) + K(x_i, x_i) - 2 \sum_{j=1}^l K(x_j, x_i) \beta_j \quad (11)$$

$D(x_i)$  大小反映了一个样本偏离其所在类总体的程度, 当  $D(x_i)$  较小时, 样本在回归线附近; 随着  $D(x_i)$  的增大,  $x_i$  远离回归线;  $D(x_i)$  大到一定程度时,  $x_i$  被认为是数据域的一个孤立点. 因此, 可以在每次增量学习后, 将支持向量中具有最大  $D(x_i)$  值的样本从工作样本集中剔除.

对于以上两种策略, 在除去一个支持向量时需进行减量学习的步骤. 减量学习是增量学习的逆过程, 也就是当前 KKT 条件 Lagrange 系数和回归函数返回到减量样本加入前的状态. 通过减量学习可以消除模型中由于直接除掉减量样本带来的影响. 参考增量学习的过程, 减量样本  $(x_k, y_k)$  从工作集中剔除后, 矩阵  $R$  按如下步骤更新:

$$R_{ij} = R_{ij} - R_{kk}^{-1} R_{ik} R_{kj}, \quad (12)$$

这里  $R_{ij}$  代表矩阵  $R$  中第  $(i, j)$  个元素.

### 3.3 ISVM 的建模步骤

假设当前工作样本集为  $X$ , 增量样本集为  $I$ . 首先在  $X$  进行训练, 得到回归函数  $f(x)$  以及  $g_i^{(*)}$ . 对于  $I$  中的每一个元素  $(x_c, y_c)$  进行如下迭代步骤:

Step 1: 初始化  $\Delta \alpha_c^{(*)} = 0$ , 对增量样本进行检验, 如果它满足 KKT 条件, 即  $g_c^{(*)} < 0$ , 终止.

Step 2: 如果增量样本违背 KKT 条件, 即  $g_c^{(*)} > 0$ , 根据以下步骤找到最大的增量  $\Delta \alpha_c^{(*)}$ :

1) 如果  $g_c^{(*)} = 0$ , 则增量样本  $(x_c, y_c)$  变为非边界支持向量, 令  $(x_c, y_c) \in X_{\text{nbvs}}$ , 根据式 (9) 更新矩阵  $R$ ;

2) 如果  $\Delta\alpha^{(*)} = C$ , 则增量样本  $(x_c, y_c)$  变为边界支持向量, 令  $(x_c, y_c) \in X_{bsv}$ , 终止迭代;

3) 根据式 (4) 及 (8) 更新 KKT 条件, 并根据 KKT 条件调整集合  $X_{bsv}, X_{nsv}, X_{nbsv}$  中的元素, 重复 Step 2, 直到这一过程收敛

Step 3: 根据启发式策略确定减量样本  $(x_k, y_k)$ , 初始化  $\Delta\alpha^{(*)} = 0$

Step 4: 如果  $\alpha^{(*)} > 0$ , 根据以下步骤找到最大的减量  $\Delta\alpha^{(*)}$ :

1) 如果  $\alpha^{(*)} = 0$ , 则减量样本  $(x_k, y_k)$  变为非支持向量, 令  $X = X \setminus \{(x_k, y_k)\}$ , 终止迭代, 进入 Step 5;

2) 根据式 (4) 及 (8) 更新 KKT 条件, 并根据 KKT 条件调整集合  $X_{bsv}, X_{nsv}, X_{nbsv}$  中的元素, 重复 Step 4 直到收敛

3) 根据式 (12) 更新矩阵  $R$  以及  $\hat{f}(x) = \sum_{i=1}^l (\alpha_i - \hat{\alpha}_i^*) K(x_i, x) + \hat{b}$ , 其中  $\hat{\alpha}_i, \hat{\alpha}_i^*, x_i$  和  $\hat{b}$  来自前一步更新过程

Step 5: 随着系统中新增量样本的到来, 重复 Step 1.


#### 4 数值仿真

根据工艺分析, 影响 PX 纯度的主要因素是吸附塔中 4 个区的区域流量<sup>[2]</sup>, 以及塔温、塔压等, 而区域流量是由外部 5 股物流的流量决定的。最终选取操作压力、脱附剂与进料比、反洗与进料比、抽出液量与抽余液比、泵回量与进料比、操作温度、转换周期作为软测量模型的输入变量, 模型输出变量为 PX 纯度, 如表 1 所示。经过预处理、归一化后得到 400 个数据样本, 其中 200 个样本用于训练, 200 个样本作为测试集进行测试


表 1 软测量模型过程变量列表

序号	变量名	设定值
1	操作压力 /MPa	0.90
2	脱附剂与进料比 /( $w_t/w_i$ )	1.60
3	反洗与进料比 /( $w_t/w_i$ )	0.08
4	抽出与抽余液比 /( $w_t/w_i$ )	0.35
5	泵回量与进料比 /( $w_t/w_i$ )	4.50
6	操作温度 /	175
7	转换周期 /s	73.5
8	PX 纯度 /%	99.4

ISVM 算法是采用 C 语言在 LBSVM<sup>[9]</sup> 的基础上改写而成, 在训练 ISVM 和 SVR 中, 核函数为高斯径向基核  $K(x_i, x_j) = e^{-p \|x_i - x_j\|^2}$ , 经过 10 倍样本交叉检验得到最优的参数  $p = 0.5, C = 20$  分别采用基于 SVR 和 ISVM 的软测量模型 (采用基于 SVDD 的样本替换策略) 的预测结果如图 2 所示



(a) SVR 预测结果比较



(b) ISVM 预测结果比较

图 2 SVR 和 ISVM 预测结果比较

从图 2 可以看出, 随着时间的推移, 采用基于 ISVM 的软测量模型, 在样本区间内拟合分析化验值要比 SVR 好, 大约在 150 个样本处, 基于 SVR 的软测量模型的预测误差显著增加, 预测曲线开始偏离分析化验值

为了验证 ISVM 在不同规模测试集上的性能, 分别在不同的测试集上比较 ISVM 和 SVR 算法的预测均方差, 其中 ISVM 分别采用两种样本替换策略, 结果如表 2 所示。从表 2 可以看出, 随着测试样本数量的增加, 基于 SVR 的软测量模型的预测均方差越来越大, 而基于 ISVM 的软测量模型的预测均方差则变化不大。这是由于基于 ISVM 的软测量模型根据测试样本进行在线增量学习, 每收集到一个样本后对模型进行修正的缘故。随着时间的推移, 其预测精度要明显高于 SVR 模型, 表现出了较好的泛化能力。另外, 对比两种替换策略可以看出, 基于数据域描述的软测量模型, 其精度要稍高于基于时间的软测量模型, 但前者需要计算特征空间的最小包含超球, 会额外增加增量学习的时间, 实际应用中可根据时间和精度的要求进行权衡, 选择合适的模型

表 2 不同测试样本集下的预测均方差

样本数	ISVM (SVDD)	ISVM (Time Based)	SVR
50	0.0973	0.0993	0.1074
100	0.0974	0.1043	0.1116
150	0.0978	0.1127	0.1324
200	0.0981	0.1118	0.1575

#### 5 结 论

本文提出了一种基于增量支持向量机的软测量建模方法, 随着增量样本的获得, 每次在模型中增加一个样本进行增量学习的同时去掉工作集中一个样本, 于是可以在软测量模型中不断增加能够代表新

工况信息样本的同时控制工作样本集的规模 将所提出的软测量建模方法用于PX 吸附分离过程中纯度的预测, 结果表明所提出的方法以及样本替换策略可以有效地增强软测量模型适应工况变化的能力, 提高其预测的精度

### 参考文献(References)

- [1] 冯孝庭 吸附分离技术[M]. 北京: 化工出版社, 2000: 46-52  
(Feng X T. *Techniquical of Fractionation by Adsorption Process* [M]. Beijing: Chemical Industry Press, 2000: 46-52 )
- [2] Pavone D, Hotier G. System Approach Modeling Applied to the Eluxyl Process[J]. *Oil & Gas Science and Technology*-rev, 2000, 55(4): 437-446
- [3] 徐敏, 俞金寿. 软测量技术[J]. *石油化工自动化*, 1998, 10(2): 1-3  
(Xu M, Yu J S. Technology of Soft Sensor [J]. *A uam ation in Petro-chemical Industry*, 1998, 10(2): 1-3
- [4] Vapnik V. *Statistical Learning Theory* [M]. New York: Wiley Springer, 1998: 146-175
- [5] 阎威武, 邵惠鹤. 支持向量机和最小二乘支持向量机的比较及应用研究[J]. *控制与决策*, 2003, 18(3): 358-360  
(Yan W W, Shao H H. Application of Support Vector M achines and Least Squares Support Vector M achines to Heart Disease Diagnoses [J]. *Control and decision*, 2003, 18(3): 358-360
- [6] Naqa I E, Yang Y. Relevance Feedback Based on Incremental Learning for Mammogram Retrieval[J]. *Image Processing*, 2003, 4(2): 7-11
- [7] Cauwenberghs G, Poggio T. Incremental and Decremental Support Vector Machine Learning [J]. *Advances in Neural Information Processing Systems*, 2000, 13(2): 147-158
- [8] Burges C J C. A tutorial on Support Vector M achines for Pattern Recognition [J]. *Data Mining and Knowledge Discovery*, 1998, 2(2): 1-47.
- [9] Chang C C, Lin C J. Training Nu-support Vector Regression: Theory and Algorithms [J]. *Neural Computation*, 2002, 14(2): 1959-1977.
- [10] Tax D M J, Duin R P W. Data Domain Description by Support Vectors [A]. *Proc of 8th European Symposium on Artificial Neural Networks* [C]. Brussels: Facto D, 1999: 251-256
- [3] Buso S, Fiasolo S, Malesani L. et al. A Dead-beat adaptive Hysteresis Current Control [J]. *Industry Applications, IEEE Trans on*, 2000, 36(4): 1174 - 1180
- [4] Kawabata Y, Kawakami T, Sasakura Y, et al. New Design Method of Decoupling Control System for Vector Controlled Induction Motor [J]. *Power Electronics, IEEE Trans on*, 2004, 19(S): 1-9
- [5] Telford D, Dunnigan M W, Williams B W. A Self-tuning Regulator for Induction Machine Vector Control [A]. *Power Electronics Specialists Conf, 2002 PESC 02*[C]. Carins, 2002, 3: 1463-1468
- [6] Nishida K, Nakaoaka M. Deadbeat Current Control with Adaptive Predictor for Three-phase Voltage-source Active Power Filter [A]. *Power Electronics Specialists Conf, 2004, PESC 04* [C]. Aachen, 2004, 2: 1010-1016
- [7] Telford D, Dunnigan M W, Williams B W. Adaptive High Bandwidth Current Control for Induction M achines [J]. *Power Electronics, IEEE Trans on*, 2003, 18(2): 527-538
- [8] Malesani L, Mattavelli P, Buso S. Robust Dead-beat Current Control for PWM Rectifiers and Active Filters [J]. *Industry Applications, IEEE Trans on*, 1999, 35(S): 613-620
- [9] Burton B, Harley R G, Diana G, et al. Implementation of a Neural Network to Adaptively Identify and Control VSI-Fed Induction Motor Stator Currents [J]. *Industry Applications, IEEE Trans on*, 1998, 34(3): 580-588
- [10] Saetio S, Torrey D A. Fuzzy Logic Control of a Space-vector PWM Current Regulator for Three-phase Power Converters [J]. *Power Electronics, IEEE Trans on*, 1998, 13(3): 419-426
- [11] Zhang C J, Dunnigan M W. Robust Adaptive Stator Current Control for an Induction Machine [A]. *Proc of 2003 IEEE Conf on* [C]. Istanbul, 2003, 1(23-25): 779-784
- [12] Sheng-Ming Yang, Chen-Haur Lee. A Deadbeat Current Controller for Field Oriented Induction Motor Drives [J]. *Power Electronics, IEEE Trans on*, 2002, 17(5): 772-778

(上接第 1101 页)