

研究论文

# 基于 ART-SVR 的过程建模及在 干点软测量中的应用

吴国庆, 颜学峰

(华东理工大学自动化研究所, 上海 200237)

**摘要:** 针对石油化工生产过程通常呈高度非线性, 且生产过程数据呈非连续、具有一定类别特性等特征, 提出基于自适应谐振神经网络 (adaptive resonance theory, ART) 和支持向量回归 (support vector regression, SVR) 相结合的建模方法 (ART-SVR)。首先, 基于建模样本, 通过 ART 将样本模式空间分割成若干模式特性相近的子空间; 然后, 对各子空间分别采用 SVR 建立各自模型, 实现基于样本模式空间分割的“分段”建模。仿真试验和在石脑油干点软测量建模的实际应用表明: ART-SVR 模型的拟合精度和预测精度均优于全局 SVR 模型。

**关键词:** 自适应谐振神经网络; 支持向量回归; 建模; 干点; 软测量

中图分类号: TP 183; TE 622

文献标识码: A

文章编号: 0438-1157 (2008) 04-0927-07

## Process modeling based on ART-SVR and its application in dry point soft measurement

WU Guoqing, YAN Xuefeng

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

**Abstract:** The petrochemical process is highly nonlinear and the observation data of the petrochemical process are non-continuous and have classified characteristics. A novel process modeling method, which combined adaptive resonance theory (ART) with support vector regression (SVR), was proposed. Firstly, ART was used to separate the input pattern space into several sub-spaces based on a modeling sample. Then, SVR was used to build up each sub-model for each sub-space. The results of simulation experiment and an application in dry point soft measurement of naphtha showed that ART-SVR could reduce the nonlinear degree of the sub-models and its fitting accuracy and prediction accuracy were both better than those of a single SVR model.

**Key words:** adaptive resonance neural networks; support vector regression; modeling; dry point; soft measurement

### 引 言

基于石油化工生产过程样本数据的建模, 已提

出了很多方法<sup>[1-2]</sup>。有各种全局多元线性回归方法, 它们具有简洁明确的解析表达形式, 建模速率高, 但由于石油化工生产过程影响因素众多且呈高度非

2007-07-23 收到初稿, 2007-11-07 收到修改稿。

**联系人:** 颜学峰。第一作者: 吴国庆 (1982-), 男, 硕士研究生。

**基金项目:** 国家自然科学基金项目 (20506003, 20776042); 教育部科学技术研究重点项目 (106073); 国家高技术研究发展计划项目 (2007AA04Z164, 2007AA04Z171)。

**Received date:** 2007-07-23.

**Corresponding author:** Prof. YAN Xuefeng. **E-mail:** yan\_xuefeng@hotmail.com

**Foundation item:** supported by the National Natural Science Foundation of China (20506003, 20776042), the Key Project of Chinese Ministry of Education (106073) and the High-tech Research and Development Program of China (2007AA04Z164, 2007AA04Z171).

线性的特征，由此所建的回归模型，其预报能力往往不能令人满意。同时，石油化工生产过程通常根据生产负荷和产品质量需求的改变以及原料的变化等进行操作条件的调整，从而积累大量具有一定类别特征的生产数据，且使过程对象呈非连续的特征。本文针对这类呈高度非线性、非连续且具有一定类别特性的石油化工过程，提出了基于自适应谐振神经网络 (adaptive resonance theory, ART) 和支持向量回归<sup>[3]</sup> (support vector regression, SVR) 相结合的建模方法。

### 1 支持向量回归 (SVR)

对于  $n$  个输入输出样本集  $\{ (x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n) \}$ ，其中  $x_i$  是  $p$  维空间的样本，即  $x_i \in R^p$ ， $y_i$  是目标输出且  $y_i \in R^1$ 。假设通过非线性映像操作数  $\Phi$  将原始  $p$  维空间的  $n$  个输入样本  $x_1, \dots, x_n$ ，映射到高维的 Hilbert 空间中，然后在 Hilbert 空间构造线性函数如下

$$f(x) = \omega^T \cdot \Phi(x) + b \tag{1}$$

根据结构风险最小化准则，综合考虑正则化项和拟合误差，将回归问题转化为下面最优化问题

$$\min_{\omega, b, \xi, \xi^*} \frac{1}{2} \omega^T \omega + C \sum_{i=1}^n \xi_i + C \sum_{i=1}^n \xi_i^* \tag{2}$$

约束

$$\begin{aligned} \omega^T \Phi(x_i) + b - y_i &\leq \epsilon + \xi_i \\ y_i - \omega^T \Phi(x_i) - b &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0, i = 1, \dots, n \end{aligned}$$

其中， $\xi_i, \xi_i^*$  为松弛变量； $\epsilon$  为预先给定的不敏感度； $C$  为预先给定的常数，控制对  $f(x)$  偏离  $y$  的惩罚程度， $C$  越大惩罚越重。

把式 (2) 最优化问题转化为较简单的对偶问题如下

$$\begin{aligned} \min_{\alpha, \alpha^*} \frac{1}{2} (\beta - \beta^*)^T Q (\beta - \beta^*) + \epsilon \sum_{i=1}^n (\beta_i - \beta_i^*) + \\ \sum_{i=1}^n y_i (\beta_i - \beta_i^*) \end{aligned} \tag{3}$$

约束

$$\sum_{i=1}^n (\beta_i - \beta_i^*) = 0, 0 \leq \beta_i, \beta_i^* \leq C, i = 1, \dots, n$$

其中， $\beta_i, \beta_i^*$  为拉格朗日乘子； $Q$  为 Gram 矩阵， $Q_{ij} = \Phi(x_i)^T \Phi(x_j) = K(x_i, x_j)$ ， $K$  为核函数或称为 Hilbert 空间的再生核，它可以是满足 Mercer 条件的任意对称实函数； $C$  为预先给定的常数，用于限制拉格朗日乘子； $\epsilon$  为预先给定的不敏

感度。

于是在再生核 Hilbert 空间中构造的线性函数转变为

$$f(x) = \sum_{i=1}^n (\beta_i^* - \beta_i) K(x_i, x) + b \tag{4}$$

其中， $K(x_i, x) = \Phi(x_i)^T \Phi(x)$ 。

除了  $\epsilon$ -SVR 以外，Scholköpfung<sup>[4]</sup> 提出了  $\nu$ -SVR 以避免事先给定  $\epsilon$ ，Suykens<sup>[5]</sup> 提出了最小二乘支持向量机 (LS-SVM) 等。

### 2 自适应谐振神经网络

自适应谐振神经网络 (ART) 能够实现输入样本的自组织聚类，将输入样本模式空间自组织地分割成若干个子空间，可以认为 ART 网络是一种向量模式识别器，它根据存储的模式对输入向量进行分类，其基本的体系结构如图 1 所示。




图 1 ART 基本体系结构

Fig. 1 Basic structure of ART

从图 1 可以看到，ART 网络是由输入层和输出层 (类别层) 两层神经元组成，输入层和输出层之间通过自底向上和自顶向下的权值连接起来。输出层的类神经元之间通过侧向连接相互抑制，即：每次只有一个类神经元被启动。自底向上的权向量  $w$  代表学到的类中心，而自顶向下的权向量  $\hat{w}$  代表期望的模式。

ART 网络的工作过程如下：当输入模式被送入网络时，与输入模式第一相似 (最相似) 的权向量  $w$  所对应的类神经元就会被启动 (竞争获胜)，被启动的类神经元会产生一个自顶向下的期望模式  $\hat{w}$ 。如果  $\hat{w}$  与输入模式匹配，则进入自适应谐振状态， $w$  与  $\hat{w}$  同时学习输入模式。如果  $\hat{w}$  与输入模式不匹配，则重置信号将屏蔽被启动的类神经元，使它暂时处于抑制状态而不能被启动。由于重置信号的作用，原先与输入模式第二相似的权向量  $w$  所对应的类神经元将被启动，其工作过程就这样类推下去。如果所有类神经元的期望模式  $\hat{w}$  都不和输

入模式匹配, 说明输入模式是一个从来没有学习过的新模式, 可以在输出层增加一个类神经元存储该输入模式。

### 3 基于 ART-SVR 的过程建模

#### 3.1 ART-SVR 的算法流程

ART 网络最基本算法有 ART1<sup>[6]</sup>、ART2<sup>[7]</sup>、ART3<sup>[8]</sup>, 目前常用的几种 ART 变形有 ART2A<sup>[9]</sup>、ART2A-E<sup>[10]</sup>、ART2A-C<sup>[11]</sup> 和 Fuzzy-ART<sup>[12]</sup> 等。文献 [13] 较深入地分析了 ART 的理论及方法。Frank 等<sup>[14]</sup> 给出了各类 ART 算法聚类性能的两项模拟试验结果。由于 ART2A-E 具有算法简单、计算量小的优点, 本文采用该算法。假设有  $n$  个输入输出训练样本集  $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ ,  $\mathbf{x}_i$  是  $p$  维空间的样本, 即  $\mathbf{x}_i \in R^p$ ,  $y_i$  是目标输出且  $y_i \in R^1$ 。ART-SVR 算法流程如下。

(1) 归一化  $n$  个输入样本  $\mathbf{x}_1, \dots, \mathbf{x}_n$ , 使每个输入样本的各分量在  $0 \sim 1$  之间, 即

$$0 \leq x_{ij} \leq 1 \quad i = 1, \dots, n, j = 1, \dots, p \quad (5)$$

(2) 预先设置 ART 网络的警戒值  $\rho$ 、学习速率  $\alpha$ 、学习次数  $t$  (学习一次为对所有的  $n$  个输入样本进行一轮的训练)、输入层的神经元个数  $p$ 、输出层的类神经元个数  $\mu = 1$ , 定义此类神经元所对应的自底向上的权向量为  $\mathbf{w}_1$ , 令  $\mathbf{w}_1 = \mathbf{x}_1$ 。

(3) 将  $n$  个输入样本  $\mathbf{x}_1, \dots, \mathbf{x}_n$  随机排序得到  $\mathbf{z}_1, \dots, \mathbf{z}_n$ , 令  $k = 1$ 。

(4) 将  $\mathbf{z}_k$  送入网络, 通过式 (6) 计算竞争获胜类神经元的标号  $j^*$  (序号) 和相似性尺度  $\eta$

$$\begin{cases} j^* = \operatorname{argmin}_{j=1, \dots, \mu} (\|\mathbf{z}_k - \mathbf{w}_j\|) \\ \eta = 1 - \frac{\|\mathbf{z}_k - \mathbf{w}_{j^*}\|}{\sqrt{p}} \end{cases} \quad (6)$$

其中,  $\|\cdot\|$  表示求欧式距离。

(5) 检验相似性尺度  $\eta$  是否达到预先设置的警戒值  $\rho$ 。

若  $\eta \geq \rho$ , 匹配合格, 进入自适应谐振状态, 进行权向量的学习调整

$$\mathbf{w}_j = \begin{cases} \mathbf{w}_j + \alpha(\mathbf{z}_k - \mathbf{w}_j) & j = j^* \\ \mathbf{w}_j & j \neq j^* \end{cases} \quad (7)$$

若  $\eta < \rho$ , 匹配不合格, 增加一个新的类神经元和相应的权向量, 用于存储一个新的输入模式, 即

$$\mu = \mu + 1 \quad (8)$$

$$\mathbf{w}_\mu = \mathbf{z}_k \quad (9)$$

(6) 判断  $k$  是否等于  $n$ 。

如果  $k \neq n$ , 令  $k = k + 1$ , 转步骤 (4);

如果  $k = n$ , 一轮训练结束, 检验学习次数是否达到预设  $t$  值: 若学习次数达到预设  $t$  值, ART2A-E 自组织聚类算法结束, 转步骤 (7); 否则, 转步骤 (3)。

(7) 将  $n$  个输入样本  $\mathbf{x}_1, \dots, \mathbf{x}_n$  重新依次输入 ART 网络, 通过式 (10) 标记每个样本所属的类别

$$j^* = \operatorname{argmin}_{j=1, \dots, \mu} (\|\mathbf{x}_k - \mathbf{w}_j\|) \quad k = 1, \dots, n \quad (10)$$

可以看出, 每个样本的类别号等于获胜类神经元标号。

(8) 将同类的样本归类, 组成  $\mu$  个输入输出训练样本集:  $\{(\mathbf{x}_1^1, y_1^1), \dots, (\mathbf{x}_{k_1}^1, y_{k_1}^1)\}, \dots, \{(\mathbf{x}_1^i, y_1^i), \dots, (\mathbf{x}_{k_i}^i, y_{k_i}^i)\}, \dots, \{(\mathbf{x}_1^\mu, y_1^\mu), \dots, (\mathbf{x}_{k_\mu}^\mu, y_{k_\mu}^\mu)\}$ , 其中  $\mathbf{x}^i$  代表第  $i$  类输入样本,  $y^i$  是第  $i$  类输出样本,  $k_i$  是第  $i$  类样本的个数。

(9) 对每类输入输出训练样本集  $\{(\mathbf{x}_1^i, y_1^i), \dots, (\mathbf{x}_{k_i}^i, y_{k_i}^i)\}$ ,  $i = 1, 2, \dots, \mu$ , 采用 SVR 建模, 总共建  $\mu$  个模型。

#### 3.2 基于 ART-SVR 模型的预测

对于一个未知的新样本  $\mathbf{x}$  (设已采用与 3.1 节相同的方法归一化到  $0 \sim 1$  之间), ART-SVR 的算法流程如下:

(1) 判断新样本  $\mathbf{x}$  属于哪一个类别  $j^*$

$$j^* = \operatorname{argmin}_{j=1, \dots, \mu} (\|\mathbf{x} - \mathbf{w}_j\|) \quad (11)$$

(2) 调用第  $j^*$  个 SVR 模型, 进行预测。

### 4 仿真试验

为了体现 ART-SVR “分段” 建模的思想, 本文将对以下分段函数进行分段建模, 数据集由式 (12) 产生

$$y = \begin{cases} x_1^2 + x_2^2 + e & x_1, x_2 \in D_1, D_1 \sim N_2\left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & 0.7 \\ 0.7 & 1 \end{bmatrix}\right) \\ x_1 + x_2 + e & x_1, x_2 \in D_2, D_2 \sim N_2\left(\begin{bmatrix} 10 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix}\right) \end{cases} \quad (12)$$

其中,  $e$  为人工加入的随机噪声, 服从一元正态分布  $N_1(0, 0.5^2)$ ; 区域  $D_1$ 、 $D_2$  服从二元正态分布。数据集由训练样本和预测样本组成, 在区域  $D_1$ 、 $D_2$  随机各取 150 个样本点, 并在每个区域内取其中的 100 个输入输出样本对作为训练样本, 剩余的 50 个输入输出样本对作为预测样本, 这样数据集

包括 200 个训练样本和 100 个预测样本。其中预测样本的输出  $y$  不含人工加入的随机噪声，以便与模型的输出进行对比，分析建立模型的真实预测能力。鉴于区域  $D_1$ 、 $D_2$  是随机得到的，所以连续进行 10 次试验，即产生 10 组数据集。


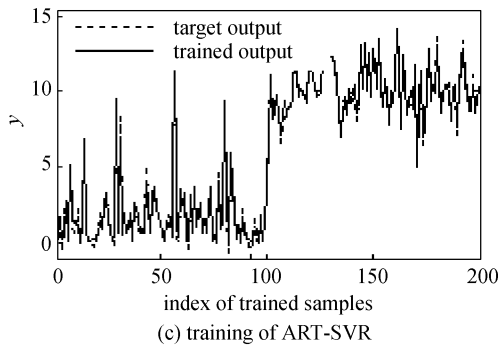
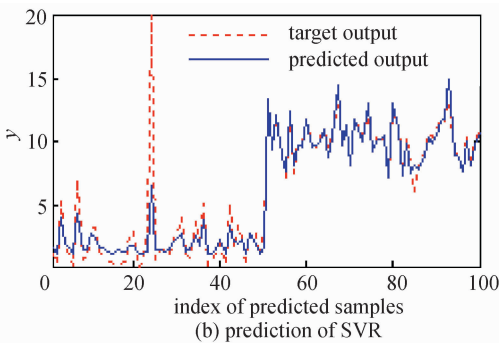
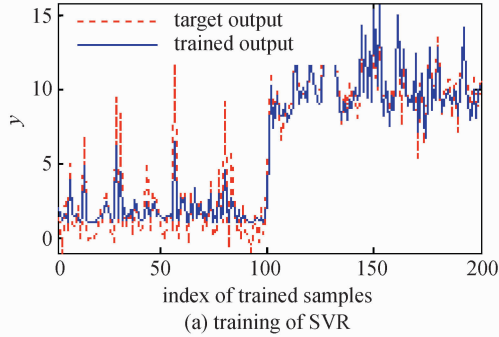


图 2 SVR 与 ART-SVR 的比较

Fig. 2 Comparison of SVR with ART-SVR

图 2 为其中一次试验中，单纯采用 SVR 建模与 ART-SVR 建模的仿真对比结果。图 2 (a) 是 SVR 的拟合曲线，图 2 (b) 是 SVR 的预测曲线，图中红色虚线为样本输出，蓝色实线为模型输出，从图中可以看出，单纯采用 SVR 建模的精度与预测能力都不理想。

ART-SVR 拟合曲线和预测曲线分别如图 2 (c)、(d) 所示，均优于 SVR。这是因为在警戒值  $\rho = 0.5$ ，学习速率  $\alpha = 0.01$  时，经过 20 轮学习后，ART2A-E 自组织地将输入样本分成 2 个子空间（相似于  $D_1$ ， $D_2$ ），从而实现了在每个子空间内对训练样本进行分段建模，提高模型拟合与预测精度。同时，从图 2 (d) 中可以看出，ART-SVR 模型具有很强抑制噪声的能力，其模型预测输出与不含人工加入随机噪声的预测样本输出几乎一致。

表 1 给出了连续 10 次试验所建立模型的拟合与预测均方误差 (mean square error, MSE)，可以看出，ART-SVR 比 SVR 具有更好的拟合和预测能力。

表 1 仿真实验中 ART-SVR 建模与 SVR 建模比较

Table 1 Comparison of ART-SVR modeling with SVR modeling in simulation experiment

Times of tests	ART-SVR		SVR	
	MSE of predicting sets	MSE of training sets	MSE of predicting sets	MSE of training sets
1	0.0096	0.2159	0.3924	0.4851
2	0.0227	0.2282	1.0354	0.6519
3	0.0154	0.2205	0.3170	0.5043
4	0.0665	0.2480	0.4320	0.6527
5	0.0582	0.2341	1.6018	0.5501
6	0.0185	0.2208	0.9933	0.5558
7	0.0516	0.2724	0.5677	0.8710
8	0.0185	0.2450	0.3725	0.5725
9	0.0216	0.1975	0.3151	0.6997
10	0.0193	0.2697	1.0522	0.6240

## 5 石油化工工业应用

### 5.1 初馏塔流程及样本数据

某常减压装置初馏塔的工艺流程如图 3 所示。原油经过脱盐脱水预处理后加热到一定的温度进入初馏塔并被切割成初顶石脑油和塔底油，以达到降

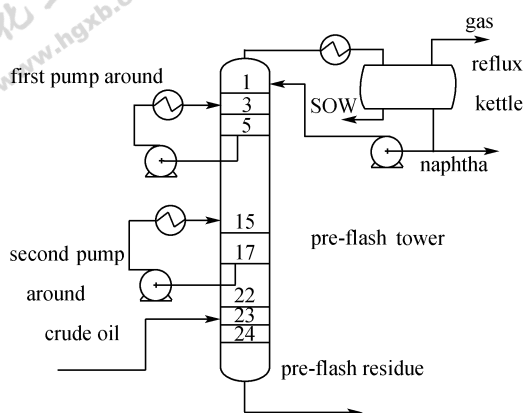


图3 初馏塔的工艺流程图

Fig. 3 Flow chart of pre-flash tower

低常压塔顶部负荷的目的；初馏塔设有顶回流，以保证精馏效果；设有两个循环回流（即初一中和初二中），以控制塔内的汽液相负荷，提高处理量。

影响初顶馏分干点 ( $y$ ,  $^{\circ}\text{C}$ ) 的几个主要因素有：初馏塔处理量 ( $x_1$ ,  $\text{kg} \cdot \text{h}^{-1}$ )、塔顶温度 ( $x_2$ ,  $^{\circ}\text{C}$ )、塔顶压力 ( $x_3$ ,  $\text{MPa}$ )、顶回流单位处理量温差 ( $x_4$ ,  $^{\circ}\text{C}$ )、回流比  $x_5$ 、初顶石脑油流量 ( $x_6$ ,  $\text{kg} \cdot \text{h}^{-1}$ )、初顶循单位处理量温差 ( $x_7$ ,  $^{\circ}\text{C}$ )、初中段单位处理量温差 ( $x_8$ ,  $^{\circ}\text{C}$ )、进料温度 ( $x_9$ ,  $^{\circ}\text{C}$ )；其中  $x_4$ 、 $x_5$ 、 $x_7$ 、 $x_8$  按式 (13) 计算

$$\begin{cases} x_4 = \frac{(x_2 - t_1)m_1}{x_1} \\ x_5 = \frac{m_1}{x_6} \\ x_7 = \frac{(t_2 - t_3)m_2}{x_1} \\ x_8 = \frac{(t_4 - t_5)m_3}{x_1} \end{cases} \quad (13)$$

式中  $t_1$  为塔顶回流温度,  $^{\circ}\text{C}$ ； $m_1$  为初顶回流量,  $\text{kg} \cdot \text{h}^{-1}$ ； $t_2$  为初一中抽出温度,  $^{\circ}\text{C}$ ； $t_3$  为初一中返塔温度,  $^{\circ}\text{C}$ ； $m_2$  为初一中循环量,  $\text{kg} \cdot \text{h}^{-1}$ ； $t_4$  为初二中抽出温度,  $^{\circ}\text{C}$ ； $t_5$  为初二中返塔温度,  $^{\circ}\text{C}$ ； $m_3$  为初二中循环量,  $\text{kg} \cdot \text{h}^{-1}$ 。

$x_1$ 、 $x_2$ 、 $x_3$ 、 $x_6$ 、 $x_9$ 、 $t_1$ 、 $m_1$ 、 $t_2$ 、 $t_3$ 、 $m_2$ 、 $t_4$ 、 $t_5$ 、 $m_3$  均可以由设备中控室的 DCS 系统直接获得,  $x_4$ 、 $x_5$ 、 $x_7$ 、 $x_8$  可以由式 (13) 实时通过 DCS 系统间接计算获得。采集 151 组影响石脑油干点的因素数据, 组成  $151 \times 9$  维输入样本数据矩阵和  $151 \times 1$  维输出样本数据。

## 5.2 初馏塔生产资料的过程建模

在警戒值  $\rho = 0.7$ , 学习速率  $\alpha = 0.01$  时, 经

过 20 轮学习, ART2A-E 自组织地将输入样本分成 4 个子空间, 在每个子空间内的输入样本个数分别为 39、41、39、32。本文采用交叉验证法, 来检验 ART-SVR 建模的泛化能力, 例如: 对于子空间 1, 只取 38 个样本进行建模, 留出 1 个样本进行预测, 这样在子空间 1 内可以建模 39 次, 得到 39 个不同样本的预测值; 同样在子空间 2 内可以建模 41 次, 得到 41 个不同样本的预测值, 依次类推下去可以得到所有 151 个样本的预测值。为了能够与单纯采用 SVR 建模进行比较, 也采用交叉验证法, 即: 只取 150 个样本进行建模, 留出 1 个样本进行预测, 建模 151 次, 同样也可以得到所有 151 个样本的预测值。

在建模过程中无论是 ART-SVR 建模还是单纯采用 SVR 建模, 都采用高斯核函数, 其宽度选取取决于交叉验证的结果, 即: 根据交叉验证的好坏, 来调整核函数的宽度, 使得预测 MSE 尽量小。

图 4 为这 4 个子空间内的预测值与目标值的对比图。图中的对角线代表预测值与目标值的偏离程度, 如果预测值与目标值相等, 则“□”落在对角线上。

图 5 (a) 是将图 4 的 4 个子图融合在一起的预测值与目标值的对比图, 图 5 (b) 是单纯采用 SVR 建模, 通过交叉验证得到预测值与目标值的对比图。从图 5 可以很直观地看出, ART-SVM 建模的预测精度比单纯采用 SVR 建模要好。

表 2 给出了两种建模方法的平均拟合 MSE 和预测 MSE, 从表中可以看出, 基于 ART-SVR 对样本分割的分段建模, 每个模型的预测精度和拟合精度, 都高于对整个样本建模。通过表 2, 还可以计算出 ART-SVR 对所有 151 个样本的预测 MSE 仅为 0.688, 比单纯采用 SVR 建模的预测精度提高了约 2 倍 ( $1.6/0.688$ )。

## 6 结 论

ART-SVR 能够将输入样本模式空间分割成若干模式特性相近的子空间, 从而实现基于样本模式空间分割的“分段”建模。仿真研究表明对于分段模型, ART-SVR 通过 ART、基于样本数据, 能自组织、有效地将样本空间分割成若干子空间, 实现“分段”建模, 提高整体模型的预测精度。同时, 仿真研究也表明了 ART-SVR 模型具有很好的


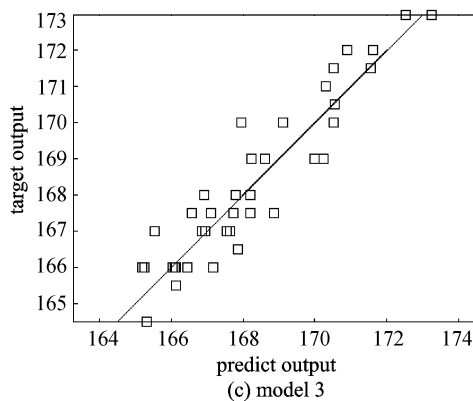




图 4 ART-SVR 泛化性能

Fig. 4 Generalization of ART-SVR

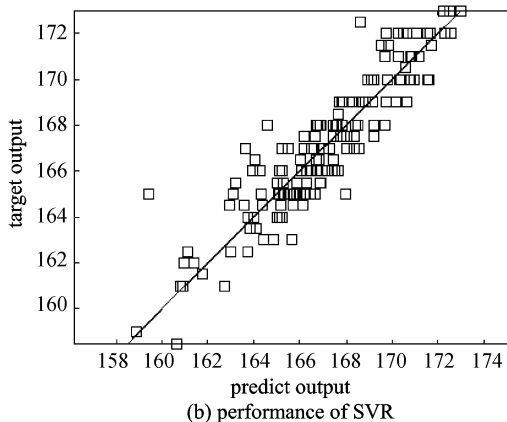
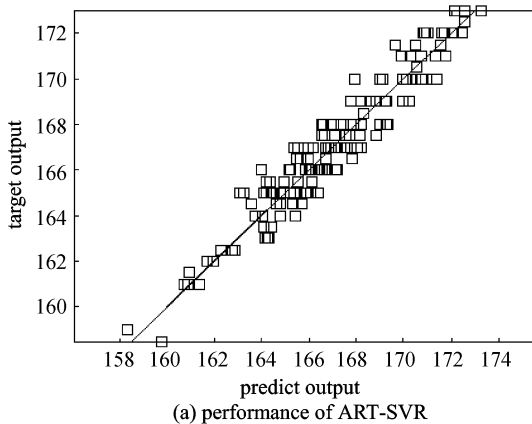


图 5 ART-SVR 与 SVR 泛化性能比较

Fig. 5 Comparison of ART-SVR with SVR on generalization

表 2 工业应用中 ART-SVR 建模与 SVR 建模比较

Table 2 Comparison of ART-SVR modeling with SVR modeling in industrial application

Item	ART-SVR				SVR
	Model 1	Model 2	Model 3	Model 4	
average of fitting MSE	0.317	0.407	0.37	0.302	1.241
MSE of predicting	0.6791	0.7033	0.676	0.6957	1.6
MSE of predicting 151 sets	0.688				1.6

抑制噪声干扰的能力。在石脑油干点软测量建模中, ART-SVR 比单纯采用 SVR 具有更好的拟合精度和预测精度, 可以为石油化工生产过程的初顶馏分干点预测与过程操作优化提供指导。

### 符号说明

$b$ —— $\epsilon$ -SVR 算法中的偏置值  
 $C$ —— $\epsilon$ -SVR 算法中的惩罚因子  
 $e$ ——一维随机噪声  
 $j$ ——ART2A-E 算法中类神经元的标号  
 $j^*$ ——ART2A-E 算法中竞争获胜类神经元的标号  
 $m_1$ ——初顶回流量,  $\text{kg} \cdot \text{h}^{-1}$   
 $m_2$ ——初一中循环量,  $\text{kg} \cdot \text{h}^{-1}$   
 $m_3$ ——初二中循环量,  $\text{kg} \cdot \text{h}^{-1}$   
 $n$ ——输入样本个数  
 $p$ ——输入样本的维数  
 $Q$ ——Gram 矩阵  
 $R^p$ —— $p$  维实向量空间  
 $t$ ——ART2A-E 算法的学习次数  
 $t_1$ ——塔顶回流温度,  $^{\circ}\text{C}$   
 $t_2$ ——初一中抽出温度,  $^{\circ}\text{C}$   
 $t_3$ ——初一中返塔温度,  $^{\circ}\text{C}$   
 $t_4$ ——初二中抽出温度,  $^{\circ}\text{C}$   
 $t_5$ ——初二中返塔温度,  $^{\circ}\text{C}$   
 $w$ ——代表 ART 网络自底向上的权向量  
 $\hat{w}$ ——代表 ART 网络自顶向下的权向量  
 $x$ ——输入样本向量, 与  $y$  构成输入输出样本对  
 $x$ ——输入样本向量的分量  
 $x_1$ ——初馏塔处理量,  $\text{kg} \cdot \text{h}^{-1}$   
 $x_2$ ——塔顶温度,  $^{\circ}\text{C}$   
 $x_3$ ——塔顶压力, MPa  
 $x_4$ ——顶回流单位处理量温差,  $^{\circ}\text{C}$   
 $x_5$ ——回流比  
 $x_6$ ——初顶石脑油流量,  $\text{kg} \cdot \text{h}^{-1}$   
 $x_7$ ——初一中单位处理量温差,  $^{\circ}\text{C}$   
 $x_8$ ——初二中单位处理量温差,  $^{\circ}\text{C}$   
 $x_9$ ——进料温度,  $^{\circ}\text{C}$   
 $y$ ——输出样本标量  
 $z$ ——代表  $x$  经归一化处理后的输入样本向量  
 $\alpha$ ——ART2A-E 算法的学习速率  
 $\beta, \beta^*$ —— $\epsilon$ -SVR 算法中的拉格朗日乘子向量  
 $\epsilon$ —— $\epsilon$ -SVR 算法中的不敏感度  
 $\eta$ ——ART2A-E 算法中的相似性尺度  
 $\mu$ ——ART 网络输出层的类神经元个数  
 $\xi_i, \xi_i^*$ ——第  $i$  个约束方程中的松弛变量

$\rho$ ——ART2A-E 算法的警戒值

$\sigma$ ——高斯核函数宽度参数

上角标

$i$ ——输入输出样本所属类别标记

下角标

$k$ ——输入输出样本向量标记

### References

- [1] Yan Xuefeng (颜学峰), Yu Juan (余娟), Qian Feng (钱锋). Development of naphtha dry point soft sensor by adaptive partial least square regression. *Journal of Chemical Industry and Engineering (China)* (化工学报), 2005, **56** (8): 1511-1515
- [2] Zhong Xuan (钟璇), Wang Shuqing (王树青). On-line soft sensing for end point of naphtha based on neural network. *Journal of Chemical Industry and Engineering (China)* (化工学报), 1998, **49** (2): 251-255
- [3] Cortes C, Vapnik V. Support vector networks. *Machine Learning*, 1995, **20**: 273-279
- [4] Scholköpf A, Smola R C, Williamson, Bartlett P L. New support vector algorithms. *Neural Computation*, 2000, **12**: 1207-1245
- [5] Suykens J. Least square SVM. *Neural Processing Letters*, 1999, **9**: 293-300
- [6] Carpenter G A, Grossberg S. The ART of adaptive pattern recognition by self-organizing neural network. *IEEE Trans. on Computer*, 1988; 77-88
- [7] Carpenter G A, Grossberg S. ART2: self organization of stable category recognition codes for analog input patterns. *Applied Optics*, 1987, **26** (23): 4919-4930
- [8] Carpenter G A, Grossberg S. ART3: hierarchical searching using chemical transmitters in self-organizing pattern recognition architecture. *Neural Networks*, 1990, **4**: 129-152
- [9] Carpenter G A, Grossberg S, Rosen D B. ART2-A: an adaptive resonance algorithm for rapid category learning and recognition. *Neural Networks*, 1991, **4**: 493-500
- [10] Yang Xingjun (杨行峻), Zhen Junli (郑君里). *Artificial Neural Network and Blind Signal Process* (人工神经网络与盲信号处理). Beijing: Tsinghua University Press, 2002
- [11] Whitely J R, Davis J F, Mehrotra A, Ahalt S C. Observations and problems applying ART2 for dynamic sensor pattern interpretation. *IEEE Transaction on Systems, Man and Cybernetics*, 1996, **26** (4): 423-437
- [12] Carpenter G A, Grossberg S, Rosen D B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Networks*, 1991, **4**: 759-771
- [13] Baraldi A, et al. Constructive feedforward ART clustering networks. *IEEE Trans. NN*, 2002, **13**: 645
- [14] Frank T, et al. Comparative analysis of fuzzy ART and ART2—a network clustering performance. *IEEE Trans. on Neural Networks*, 1998, **9** (3): 544-559