

## 粗糙 $\epsilon$ -支持向量回归模型<sup>\*</sup>

张仕光<sup>1,2</sup>, 米据生<sup>1,3\*\*</sup>, 胡清华<sup>4</sup>

(1. 河北师范大学数学与信息科学学院, 石家庄, 050024; 2. 衡水学院数学与计算机学院, 衡水, 053000;  
3. 河北省计算数学与应用重点实验室, 石家庄, 050024; 4. 天津大学计算机科学与技术学院, 天津, 300072)

**摘要:** 在  $\epsilon$ -支持向量回归和粗糙  $v$ -支持向量回归模型的基础上, 研究了新的粗糙  $\epsilon$ -支持向量回归模型。利用固定对称边界粗糙  $\epsilon$ -不敏感损失函数, 得到粗糙  $\epsilon$ -不敏感管, 构造固定对称边界粗糙  $\epsilon$ -支持向量回归模型; 利用固定非对称边界粗糙-不敏感损失函数, 得到粗糙  $\epsilon^u - \epsilon^d$ -不敏感管, 构造固定非对称边界粗糙  $\epsilon$ -支持向量回归模型。通过引进 Lagrange 函数和根据 KKT 条件, 处理粗糙  $\epsilon$ -支持向量回归模型的对偶问题。

**关键词:**  $\epsilon$ -支持向量回归, 粗糙边界, 粗糙  $\epsilon$ -支持向量回归, 粗糙集

## Rough $\epsilon$ -support vector regression model

Zhang Shi-Guang<sup>1,2</sup>, Mi Ju-Sheng<sup>1,3</sup>, Hu Qing-Hua<sup>4</sup>

(1. College of Mathematics and Information Science, Hebei Normal University, Shijiazhuang, 050024, China;  
2. College of Mathematics and Computer Science, Hengshui University, Hengshui, 053000, China;  
3. Hebei Key Laboratory of Computational Mathematics and Applications, Shijiazhuang, 050024, China;  
4. School of Computer Science and Technology, Tianjin University, Tianjin, 300072, China)

**Abstract:** Two new rough  $\epsilon$ -support vector regression models are proposed based on  $\epsilon$ -support vector regression, rough  $v$ -support vector regression and rough set theory. Firstly, a rough boundary  $\epsilon$ -insensitive tube is defined with fixed symmetrical boundary rough  $\epsilon$ -insensitive loss function, the method of optimization and  $\epsilon$ -support vector regression model. Moreover we design a fixed symmetrical boundary rough  $\epsilon$ -support vector regression model(RFSM- $\epsilon$ -SVR). Secondly, we extend the model to the case that asymmetrical loss function is considered. Finally, according to Karush-Kuhn-Tucker(KKT)conditions, we derive their dual problems by introducing the Lagrange functional into rough  $\epsilon$ -support vector regression models.

**Key words:**  $\epsilon$ -support vector regression, rough boundary, rough  $\epsilon$ -support vector regression, rough set

\* 基金项目: 国家自然科学基金(61170107, 61222210), 河北省高等学校科学研究计划(Z2010188)

收稿日期: 2013-06-20

\*\* 通讯联系人, E-mail: mijsh@263.net

支持向量回归方法已成功应用于研究和应用等各个领域,并吸引了人们的广泛关注<sup>[1~7]</sup>.设给定训练集  $D_l = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$ , 其中  $x_i \in R^n, y_i \in R, i=1, \dots, l$ . 假定  $D_l$  是某个概率分布  $P(x, y)$  上选取的独立同分布的样本, 给定损失函数为  $c(x, y, f(x))$ .

Vapnik、Cortes<sup>[1,2]</sup> 提出  $\epsilon$ -不敏感损失函数:

$$c(x, y, f(x)) = |y - f(x)|_{\epsilon} \quad (1)$$

其中:

$$|y - f(x)|_{\epsilon} = \begin{cases} 0 & |y - f(x)| \leq \epsilon \\ |y - f(x)| - \epsilon & |y - f(x)| > \epsilon \end{cases}$$

$\epsilon$  是给定的正数.

Yang 等<sup>[6,7]</sup> 提出固定非对称边界  $\epsilon$ -不敏感损失函数:

$$c(x_i, y_i, f(x_i)) = \begin{cases} 0 & -\epsilon_i^d \leq y_i - f(x_i) \leq \epsilon_i^u \\ y_i - f(x_i) - \epsilon_i^u & y_i - f(x_i) \geq \epsilon_i^u \\ f(x_i) - y_i - \epsilon_i^d & f(x_i) - y_i \geq \epsilon_i^d \end{cases} \quad (2)$$

其中  $\epsilon_i^u, \epsilon_i^d$  分别对应第  $i$  个上边界和下边界. 当  $\epsilon_i^u, \epsilon_i^d (i=1, 2, \dots, l)$  为同一个常数时, 称为固定对称边界, 式(2)即为式(1)的  $\epsilon$ -不敏感损失函数; 当  $\epsilon_i^d = \epsilon^d$  和  $\epsilon_i^u = \epsilon^u (i=1, \dots, l)$  且  $\epsilon^u \neq \epsilon^d$  时, 称为固定非对称边界.

Pawlak 等提出的粗糙集模型<sup>[8~13]</sup>是处理各种不完备信息的有效工具. Zhao<sup>[14]</sup>、Lingras 等<sup>[15]</sup>把粗糙集模型和支持向量回归模型结合起来, 分别提出粗糙  $\nu$ -支持向量回归和粗糙支持向量回归模型, 取得了较好的效果.

本文在  $\epsilon$ -支持向量回归和粗糙  $\nu$ -支持向量回归模型的基础上, 研究了新的粗糙  $\epsilon$ -支持向量回归模型. 应用固定对称边界粗糙  $\epsilon$ -不敏感损失函数, 构造固定对称边界粗糙  $\epsilon$ -支持向量回归模型; 应用固定非对称边界粗糙  $\epsilon$ -不敏感损失函数, 构造固定非对称边界粗糙  $\epsilon$ -支持向量回归模型.

## 1 粗糙集理论

粗糙集理论是利用集合的上近似、下近似与边界等概念而建立的, 是处理不精确、不一致、不完备等各种不完备信息的有效工具, 可以

直接对数据进行分析和推理, 从中发现隐含的知识, 揭示潜在的规律, 因此是一种天然的数据挖掘或者知识发现方法. 设非空有限论域  $U = \{x_1, x_2, \dots, x_n\}$ ,  $A$  为非空有限属性集, 对任意属性子集  $B \subseteq A$ , 定义  $U$  上的等价关系(也称为不可辨识关系)  $R$ :

$$R = \{(x_i, x_j) \mid \forall a \in B, a(x_i) = a(x_j)\}$$

其中  $a(x_i)$  表示属性  $a$  在点  $x$  的值. 等价关系  $R$  把  $U$  划分成一些等价类, 表示为  $U/R$ . 对于一个集合  $Y \subseteq U$ ,  $Y$  的下近似定义为:

$$\underline{R}(Y) = \bigcup \{X \in U/R \mid X \subseteq Y\} \quad (3)$$

$Y$  的上近似定义为:

$$\bar{R}(Y) = \bigcup \{X \in U/R \mid X \cap Y \neq \emptyset\} \quad (4)$$

由式(3)、(4), 定义分类精度:

$$\rho_R = 1 - \frac{|\underline{R}(Y)|}{|\bar{R}(Y)|} \quad (5)$$

若  $0 < \rho_R \leq 1$ , 则  $Y$  是粗糙集; 若  $\rho_R = 1$ , 则  $Y$  是经典集.

## 2 $\epsilon$ -支持向量回归模型

Vapnik、Cortes<sup>[1,2]</sup> 利用  $\epsilon$ -不敏感损失函数得到  $\epsilon$ -支持向量回归模型( $\epsilon$ -support vector regression model,  $\epsilon$ -SVR)的原问题为:

$$\begin{aligned} \min \{g_{P_{\epsilon}} = \frac{1}{2} \bar{\omega}^T \bar{\omega} + C/l (\sum_{i=1}^l (\xi_i + \xi_i^*))\} \\ \text{s. t. } \begin{cases} \bar{\omega}^T \cdot \phi(x_i) + b - y_i \leq \epsilon + \xi_i \\ y_i - \bar{\omega}^T \cdot \phi(x_i) - b \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, i=1, 2, \dots, l \end{cases} \end{aligned} \quad (6)$$

其中  $\epsilon$  是给定的,  $\phi: R^n \rightarrow H$  为核映射,  $H$  为 Hilbert 空间.

引进 Lagrange 泛函, 利用 KKT 条件可得  $\epsilon$ -SVR 的对偶问题<sup>[3,4]</sup>:

$$\begin{aligned} \max \{g_{D_{\epsilon}} = -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \\ \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i - \epsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i)\} \\ \text{s. t. } \begin{cases} \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C/l, i=1, \dots, l \end{cases} \end{aligned} \quad (7)$$

其中  $(\phi(x_i), \phi(x_j))$  为  $H$  空间中的内积,  $K(x_i, x_j) = (\phi(x_i), \phi(x_j))$  为核函数.

从上述对偶问题解得最优值  $\alpha_i, \alpha_i^*$  ( $i=1, \dots, l$ ), 可得  $\varepsilon$ -SVR 决策函数:

$$f(x) = \bar{\omega}^T \cdot \phi(x) + b = \sum_{i \in RSV} (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (8)$$

其中  $RSV$  表示  $(\alpha_i^* - \alpha_i) \neq 0$  所对应的向量, 称为支持向量.

### 3 固定对称边界粗糙 $\varepsilon$ -支持向量回归模型

利用  $\varepsilon$ -不敏感损失函数(式(1)), 构造固定对称边界粗糙  $\varepsilon$ -不敏感损失函数:

$$l_{R-\varepsilon}(x, y, f(x)) = |y - f(x)|_{R-\varepsilon} \quad (9)$$

其中:

$$|y - f(x)|_{R-\varepsilon} = \begin{cases} 0 & |y - f(x)| \leq \varepsilon_1 \\ \varepsilon_2 - |y - f(x)| & |\varepsilon_1 - \varepsilon_2| < |y - f(x)| < \varepsilon_2 \\ |\varepsilon_2 - |y - f(x)|| & |\varepsilon_2 - |y - f(x)|| \geq \varepsilon_2 \end{cases}$$

这里  $\varepsilon_1, \varepsilon_2$  ( $\varepsilon_1 < \varepsilon_2$ ) 是给定的正数.

利用  $\varepsilon$ -不敏感损失函数构造的  $\varepsilon$ -SVR 只考虑单个对称  $\varepsilon$ -不敏感管, 落在  $\varepsilon$ -不敏感管内部的样本是非支持向量, 落在  $\varepsilon$ -不敏感管的边界上或外边的样本是支持向量. 根据粗糙集理论和最优化理论, 利用  $\varepsilon_1, \varepsilon_2$  代替  $\varepsilon$  构造固定对称边界粗糙  $\varepsilon$ -不敏感损失函数, 得到固定对称粗糙  $\varepsilon$ -不敏感管的边界, 称之为粗糙  $\varepsilon$ -不敏感管. 采用固定对称边界粗糙  $\varepsilon$ -不敏感损失函数, 提出固定对称边界粗糙  $\varepsilon$ -支持向量回归模型(Fixed Symmetrical Boundary Rough  $\varepsilon$ -Support Vector Regression Model, RFSM  $\varepsilon$ -SVR).

RFSM  $\varepsilon$ -SVR 的原问题为:

$$\min \{g_{P_\varepsilon}\} = \frac{1}{2} \bar{\omega}^T \bar{\omega} + C/l \left( \sum_{i=1}^l (\xi_i + \xi_i^*) + \delta \sum_{i=1}^l (\eta_i + \eta_i^*) \right) \quad (10)$$

s. t.  $\begin{cases} \bar{\omega}^T \cdot \phi(x_i) + b - y_i \leq \varepsilon_1 + \xi_i + \eta_i \\ y_i - \bar{\omega}^T \cdot \phi(x_i) - b \leq \varepsilon_2 + \xi_i^* + \eta_i^* \\ 0 \leq \xi_i, \xi_i^* \leq \varepsilon_2 - \varepsilon_1 \\ \eta_i, \eta_i^* \geq 0, i=1, \dots, l \end{cases}$

其中  $\varepsilon_1, \varepsilon_2 \geq 0, \varepsilon_2 \geq \varepsilon_1, \delta \geq 1$  是给定的.

**定理 1** RFSM  $\varepsilon$ -SVR 对偶问题为:

$$\begin{aligned} \max \{g_{P_\varepsilon}\} = & -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \\ & \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i - \varepsilon_2 \sum_{i=1}^l (\alpha_i^* + \alpha_i) + 2C/l(\varepsilon_2 - \varepsilon_1) \} \\ \text{s. t. } & \begin{cases} \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq \delta C/l, i=1, \dots, l \end{cases} \end{aligned} \quad (11)$$

**证明** 引入 Lagrange 函数  $L(\bar{\omega}, b, \xi, \xi^*, \eta, \eta^*)$ :

$$\begin{aligned} L(\bar{\omega}, b, \xi, \xi^*, \eta, \eta^*) = & \frac{1}{2} \bar{\omega}^T \bar{\omega} + C/l \left( \sum_{i=1}^l \xi_i + \xi_i^* \right) + \\ & \delta \sum_{i=1}^l (\eta_i + \eta_i^*) - \sum_{i=1}^l (\beta_i \eta_i + \beta_i^* \eta_i^*) - \\ & \sum_{i=1}^l \alpha_i (\varepsilon_1 + \xi_i + \eta_i - \bar{\omega}^T \phi(x_i) - b + y_i) - \\ & \sum_{i=1}^l \alpha_i^* (\varepsilon_1 + \xi_i^* + \eta_i^* + \bar{\omega}^T \phi(x_i) + b - y_i) - \\ & \sum_{i=1}^l \gamma_i (\varepsilon_2 - \varepsilon_1 - \xi_i) - \sum_{i=1}^l \gamma_i^* (\varepsilon_2 - \varepsilon_1 - \xi_i^*) \end{aligned}$$

其中  $\alpha_i \geq 0, \alpha_i^* \geq 0, \beta_i \geq 0, \beta_i^* \geq 0, \gamma_i \geq 0, \gamma_i^* \geq 0$ ,  $i=1, \dots, l$  是 Lagrange 乘子. 由 KKT 条件得 RFSM  $\varepsilon$ -SVR 对偶问题(式(11)).

从对偶问题(式(11))解得最优值  $\alpha_i, \alpha_i^*$  ( $i=1, \dots, l$ ) 可得 RFSM  $\varepsilon$ -SVR 的决策函数:

$$f(x) = \bar{\omega}^T \phi(x) + b = \sum_{i \in RSV} (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (12)$$

其中  $RSV$  表示  $(\alpha_i^* - \alpha_i) \neq 0$  所对应的样本集.

(1) 当  $\alpha_i \in (0, C/l)$ ,  $\alpha_i^* = 0$ , 或者  $\alpha_i \in (C/l, \delta C/l)$ ,  $\alpha_i^* = 0$  时:

$$b = y_j - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_j) + \varepsilon_1$$

(2) 当  $\alpha_i^* \in (0, C/l)$ ,  $\alpha_i = 0$ , 或者  $\alpha_i^* \in (C/l, \delta C/l)$ ,  $\alpha_i = 0$  时:

$$b = y_k - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_k) - \varepsilon_1$$

(3) 当  $j \in \{i : (\alpha_i^* - \alpha_i) \in (0, C/l)\}, k \in \{i : (\alpha_i^* - \alpha_i) \in (-C/l, 0)\}$ ; 或当  $j \in \{i : (\alpha_i^* - \alpha_i) \in (C/l, \delta C/l)\}, k \in \{i : (\alpha_i^* - \alpha_i) \in (-\delta C/l, -C/l)\}$  时:

$$b = \frac{1}{2} \{ y_j + y_k - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_j) - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_k) \}$$

## 4 固定非对称边界粗糙 $\epsilon$ -支持向量回归模型

利用固定非对称边界 $\epsilon$ -不敏感损失函数(式(2)),构造固定非对称边界粗糙 $\epsilon$ -不敏感损失函数:

$$l_{R-\epsilon}(x, y, f(x)) = l_{-R-\epsilon}(x, y, f(x)) + l_{R-\epsilon}^-(x, y, f(x)) \quad (13)$$

其中:

$$\begin{aligned} l_{-R-\epsilon}(x_i, y_i, f(x_i)) &= \\ \begin{cases} 0 & f(x_i) - y_i \leq \epsilon^d \\ \epsilon^{dd} - (f(x_i) - y_i) & \epsilon^d < f(x_i) - y_i \leq \epsilon^{dd} \\ (f(x_i) - y_i) - \epsilon^{dd} & f(x_i) - y_i \geq \epsilon^{dd} \end{cases} \\ l_{R-\epsilon}^-(x_i, y_i, f(x_i)) &= \\ \begin{cases} 0 & y_i - f(x_i) \leq \epsilon^u \\ \epsilon^{uu} - (y_i - f(x_i)) & \epsilon^u < y_i - f(x_i) \leq \epsilon^{uu} \\ (y_i - f(x_i)) - \epsilon^{uu} & y_i - f(x_i) \geq \epsilon^{uu} \end{cases} \end{aligned}$$

这里 $\epsilon^d, \epsilon^{dd}, \epsilon^u, \epsilon^{uu}$ 是给定的正数, $\epsilon^{dd} \geq \epsilon^d, \epsilon^{uu} \geq \epsilon^u, \epsilon^u, \epsilon^d > 0$ .

根据粗糙集理论和最优化理论,利用 $\epsilon^{uu}$ 、 $\epsilon^{dd}$ 、 $\epsilon^u$ 、 $\epsilon^d$ 代替 $\epsilon^u$ 、 $\epsilon^d$ ,构造固定非对称边界粗糙 $\epsilon$ -不敏感损失函数,得到固定非对称粗糙 $\epsilon^u-\epsilon^d$ -不敏感管的边界,称之为粗糙 $\epsilon^u-\epsilon^d$ -不敏感管.采用固定非对称边界粗糙 $\epsilon$ -不敏感损失函数,我们提出固定非对称边界粗糙 $\epsilon$ -支持向量回归模型(Fixed Asymmetrical Boundary Rough $\epsilon$ -Support Vector Regression Model, RFAM $\epsilon$ -SVR).

RFAM $\epsilon$ -SVR的原问题可描述为:

$$\begin{aligned} \min \{ g_{P'_{\epsilon^u, \epsilon^d}} \} &= \frac{1}{2} \bar{\omega}^T \bar{\omega} + C/l \left( \sum_{i=1}^l (\xi_i + \xi_i^*) + \delta \sum_{i=1}^l (\eta_i + \eta_i^*) \right) \\ \text{s.t.} & \begin{cases} \bar{\omega}^T \phi(x_i) + b - y_i \leq \epsilon^d + \xi_i + \eta_i \\ y_i - \bar{\omega}^T \phi(x_i) - b \leq \epsilon^u + \xi_i^* + \eta_i^* \\ 0 \leq \xi_i \leq \epsilon^{dd} - \epsilon^d, \eta_i \geq 0, i=1, \dots, l \\ 0 \leq \xi_i^* \leq \epsilon^{uu} - \epsilon^u, \eta_i^* \geq 0, i=1, \dots, l \end{cases} \quad (14) \end{aligned}$$

其中 $\epsilon^{dd} \geq \epsilon^d, \epsilon^{uu} \geq \epsilon^u, \epsilon^u, \epsilon^d > 0, \delta \geq 1$ 是给定的.

**定理2** RFAM $\epsilon$ -SVR的对偶问题为:

$$\begin{aligned} \max \{ g_{D_\epsilon} \} &= -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \\ &\quad \sum_{i=1}^l (\alpha_i^* - \alpha_i) y_i - \epsilon^{dd} \sum_{i=1}^l \alpha_i - \\ &\quad \epsilon^{uu} \sum_{i=1}^l \alpha_i^* + C/l(\epsilon^{dd} - \epsilon^d + \epsilon^{uu} - \epsilon^u) \} \\ \text{s.t.} & \begin{cases} \sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq \delta C/l, i=1, \dots, l \end{cases} \quad (15) \end{aligned}$$

**证明** 引入Lagrange函数 $L(w, b, \xi, \xi^*, \eta, \eta^*)$ :

$$\begin{aligned} L(w, b, \xi, \xi^*, \eta, \eta^*) &= \frac{1}{2} \bar{\omega}^T \bar{\omega} + C/l \left( \sum_{i=1}^l (\xi_i + \xi_i^*) + \delta \sum_{i=1}^l (\eta_i + \eta_i^*) \right) - \\ &\quad \sum_{i=1}^l \alpha_i (\epsilon^d + \xi_i + \eta_i - \bar{\omega}^T \phi(x_i) - b + y_i) - \\ &\quad \sum_{i=1}^l \alpha_i^* (\epsilon^u + \xi_i^* + \eta_i^* + \bar{\omega}^T \phi(x_i) + b - y_i) - \\ &\quad \sum_{i=1}^l \gamma_i (\epsilon^{dd} - \epsilon^d - \xi_i) - \sum_{i=1}^l \gamma_i^* (\epsilon^{uu} - \epsilon^u - \xi_i^*) \end{aligned}$$

其中: $\alpha_i \geq 0, \alpha_i^* \geq 0, \beta_i \geq 0, \beta_i^* \geq 0, \gamma_i \geq 0, \gamma_i^* \geq 0, i=1, \dots, l$ 是Lagrange乘子.由KKT条件得RFAM $\epsilon$ -SVR的对偶问题(式(15)).

从对偶问题(式(15))解得最优值 $\alpha_i, \alpha_i^* (i=1, \dots, l)$ ,可得RFAM $\epsilon$ -SVR的决策函数:

$$f(x) = \bar{\omega}^T \phi(x) + b = \sum_{i \in RSV} (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (16)$$

其中 $RSV$ 表示 $(\alpha_i^* - \alpha_i) \neq 0$ 所对应的样本集.

(1)当 $\alpha_i \in (0, C/l), \alpha_i^* = 0$ ,或者 $\alpha_i \in (C/l, \delta C/l), \alpha_i^* = 0$ 时:

$$b = y_j - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_j) + \epsilon_d$$

(2)当 $\alpha_i^* \in (0, C/l), \alpha_i = 0$ ,或者 $\alpha_i^* \in (C/l, \delta C/l), \alpha_i = 0$ 时:

$$b = y_k - \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x_k) - \epsilon_u$$

## 5 结 论

根据粗糙集理论和最优化理论,利用固定对称边界粗糙  $\epsilon$ -不敏感损失函数,得到  $\epsilon$ -不敏感管的粗糙边界,称之为粗糙  $\epsilon$ -不敏感管,进而构造固定对称边界粗糙  $\epsilon$ -支持向量回归模型(RFSM  $\epsilon$ -SVR). 当  $\epsilon_2 = \epsilon_1 = \epsilon$  时,RFSM  $\epsilon$ -SVR 即为  $\epsilon$ -SVR. 利用固定非对称边界粗糙  $\epsilon$ -不敏感损失函数,得到  $\epsilon^u - \epsilon^d$ -不敏感管的粗糙边界,称之为粗糙  $\epsilon^u - \epsilon^d$ -不敏感管,进而构造固定非对称边界粗糙  $\epsilon$ -支持向量回归模型(RFAM  $\epsilon$ -SVR). 当  $\epsilon^{uu} = \epsilon^u$ ,  $\epsilon^{dd} = \epsilon^d$  时,RFAM  $\epsilon$ -SVR 即为 RFSM  $\epsilon$ -SVR.

类似的,可以利用上述方法得到固定对称边界粗糙  $\epsilon$ -支持向量分类与固定非对称边界粗糙  $\epsilon$ -支持向量分类模型.

### References

- [1] Vapnik V. The nature of statistical learning theory. New York: Springer, 1995, 188.
- [2] Cortes C, Vapnik V. Support vector networks. Machine Learning, 1995, 20: 273~297.
- [3] Bai J W, Wang W J, Guo H S. A novel support vector machine active learning strategy. Journal of Nanjing University (Natural Sciences), 2012, 48(2): 182~189. (白龙飞, 王文剑, 郭虎升. 一种新的支持向量机主动学习策略. 南京大学学报(自然科学), 2012, 48(2): 182~189).
- [4] Deng N Y, Tian Y J. New method of data mining: support vector machine. Beijing: Science Press, 2006, 408. (邓乃杨、田英杰. 数据挖掘中的新方法: 支持向量机. 北京: 科学出版社, 2006, 408).
- [5] Smola A, Schölkopf B. A tutorial on support vector regression. Statistics and Computing, 2004, 14(3): 199~222.
- [6] Yang H, Chan L, King I. Support vector machine regression for volatile stock market prediction. Yin H, Allinson N, Freeman R, et al. Intelligent Data Engineering and Automated Learning. Springer, Lecture Notes in Computer Science (LNCS), 2002, 2412: 391~396.
- [7] Yang H. Margin variations in support vector regression for the stock market prediction. Phil M. Dissertation, Department of Computer Science and Engineering. The Chinese University of Hong Kong. <http://www.svms.org/finance/Yang2003.6.pdf>, 2013-06.
- [8] Pawlak Z. Rough sets. International Journal of Computer and Information Science. 1982, 11(5): 341~356.
- [9] Pawlak Z. Rough sets: Theoretical aspects of reasoning about data. Dordrecht: Kluwer Academic Publishers, 1991, 229.
- [10] Pawlak Z, Skowron A. Rudiments of rough sets. Information Science, 2007, 177: 3~27.
- [11] Zhang W X, Liang Y, Wei W Z. Information systems and knowledge discovery. Beijing: Science Press, 2003, 244. (张文修, 梁怡, 吴伟志. 信息系统与知识发现. 北京: 科学出版社, 2003, 244).
- [12] Hu Q H, Yu D R. Application of rough set calculation. Beijing: Science Press, 2012, 184. (胡清华, 于达仁. 应用粗糙集计算. 北京: 科学出版社, 2012, 184).
- [13] Wang G Y, Yao Y Y, Yu H. A survey on rough set theory and applications. Chinese Journal of Computers, 2009, 32(7): 1229~1247. (王国胤, 姚一豫, 于洪. 粗糙集理论与应用研究综述. 计算机学报, 2009, 32(7): 1229~1247).
- [14] Zhao Y P, Sun J G. Rough v-support vector regression. Expert Systems with Applications, 2009, 36(6): 9793~9798.
- [15] Lingras P, Butz C J. Rough support vector regression. European Journal of Operational Research, 2010, 206(2): 445~455.