

柔性支持向量回归及其在故障检测中的应用

易辉¹ 宋晓峰¹ 姜斌¹ 刘宇芳^{1,2} 周智华²

摘要 支持向量回归 (Support vector regression, SVR) 的学习性能及泛化性能取决于参数设置. 在常规方法中, 这些参数以固定值形式参与运算, 而当面对复杂分布的数据集时, 可能无法挑选出一组能够胜任各种分布情况的参数, 参数设置需要在过拟合和欠拟合之间进行取舍. 因此, 本文提出一种能够根据样本分布进行参数自我调整的柔性支持向量回归算法 (Flexible support vector regression, F-SVR). 该算法根据样本分布的复杂度, 将训练样本划分为多个区域, 在训练过程中, F-SVR 为不同区域设置不同的训练参数, 有效避免了过拟合与欠拟合. 本文首先采用一组人工数据对所提算法有效性进行验证, 在实验中, F-SVR 在保持学习能力的同时, 具备较传统方法更优秀的泛化性能. 最后, 本文将该算法运用至高频电源故障的实际检测, 效果良好.

关键词 支持向量回归, 柔性, 故障检测, 电源

引用格式 易辉, 宋晓峰, 姜斌, 刘宇芳, 周智华. 柔性支持向量回归及其在故障检测中的应用. 自动化学报, 2013, 39(3): 272–284

DOI 10.3724/SP.J.1004.2013.00272

Flexible Support Vector Regression and Its Application to Fault Detection

YI Hui¹ SONG Xiao-Feng¹ JIANG Bin¹ LIU Yu-Fang^{1,2} ZHOU Zhi-Hua²

Abstract Hyper-parameters, which determine the ability of learning and generalization for support vector regression (SVR), are usually fixed during training. Thus when SVR is applied to complex system modeling, this parameters-fixed strategy leaves the SVR in a dilemma of selecting rigorous or slack parameters due to complicated distributions of sample dataset. Therefore, in this paper we proposed a flexible support vector regression (F-SVR) in which parameters are adaptive to sample dataset distributions during training. The method F-SVR divides the training sample dataset into several domains according to the distribution complexity, and generates a different parameter set for each domain. The efficacy of the proposed method is validated on an artificial dataset, where F-SVR yields better generalization ability than conventional SVR methods while maintaining good learning ability. Finally, we also apply F-SVR successfully to practical fault detection of a high frequency power supply.

Key words Support vector regression (SVR), flexible, fault detection, power supply

Citation Hui Yi, Xiao-Feng Song, Bin Jiang, Yu-Fang Liu, Zhi-Hua Zhou. Flexible support vector regression and its application to fault detection. *Acta Automatica Sinica*, 2013, 39(3): 272–284

支持向量回归 (Support vector regression,

SVR) 是 Vapnik 于 1995 年提出的基于结构风险最小化原则的函数拟合工具^[1]. 与传统拟合方法, 如神经网络方法、最小二乘方法相比, 该方法所需训练样本量更少, 且具有更好的泛化性能, 因此引起了研究者广泛的兴趣, 被应用至时序样本的预测问题^[2–3]、过程控制^[4] 及故障诊断^[5] 等领域. SVR 方法的学习性能及泛化性能在很大程度上取决于参数的设置, 在近二十年的时间中, 研究者针对 SVR 参数设置问题, 展开了广泛的探讨, 也获得了很多有效成果: Cherkassky 等在 1999 年通过 VC 推广界控制模型的复杂度^[6]; Vapnik 和 Chapelle^[7–8] 采用期望训练误差率和泛化误差率对回归进行调节; Schölkopf 等^[9–10] 提出了著名的 ν -SVR 算法, 该算法根据给定的先验知识, 自动地对支持向量回归中的一项参数 “ ϵ ” 进行设置, Kwok 和 Tsang^[11] 在 2003 年, 将该方法在高斯噪声条件下进行了完善.

尽管如此, SVR 参数的设定在理论上尚未达成

收稿日期 2011-09-15 录用日期 2012-10-14
Manuscript received September 15, 2011; accepted October 14, 2012

国家自然科学基金 (61034005, 61171191, 61203072, 61273171), 江苏省自然科学基金 (BK2010500), 国家教育部博士点基金 (20113218110011), 江苏高校优势学科建设工程资助项目, 工业控制技术国家重点实验室开放课题 (ICT1234) 资助

Supported by National Natural Science Foundation of China (61034005, 61171191, 61203072, 61273171), Natural Science Foundation of Jiangsu Province (BK2010500), the Doctoral Fund of Ministry of Education of China (20113218110011), the Priority Academic Program Development (PAPD) of Jiangsu Higher Education Institutions, and the Open Project of State Key Laboratory of Industrial Control Technology (ICT1234)

本文责任编辑 钟麦英

Recommended by Associate Editor ZHONG Mai-Ying

1. 南京航空航天大学自动化学院 南京 210016 2. 国电科学技术研究院 南京 210031

1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016 2. Guodian Science and Technology Research Institute, Nanjing 210031

该文的英文版同时发表在 *Acta Automatica Sinica*, vol. 39, no. 3, pp. 272–284, 2013.

共识. 在现实应用中, 参数设定通常依赖于现有的一些工程技巧, 如交叉验证^[11-12]、梯度下降法^[13]、群智能^[14-16]等, 这些方法为参数设置提供了很好的工程指导, 但是在应用中计算量巨大、耗时过多. 因此, Cherkassky 等^[17]在 2004 年为 SVR 的参数设定提供了经验公式, 方便参数设定的快速实现.

传统参数设定方法所得到的回归参数, 在回归过程中以全局变量的形式存在的, 即针对任意分布的样本, 回归参数始终为固定数值. 面对复杂分布训练样本, 该类方法很难挑选出一组能符合各种数据分布要求的参数. 因此, 自适应式参数设置方法近期备受关注^[18-20], 这些方法在回归时, 能够根据样本分布自动地调节参数设置, 从而获得比传统的固定参数方法更佳的回归性能. 例如, Hao 在 2010 年提出 Par- v -SVR 方法^[21], 将原本固定的 ε 参数改为随样本变化的函数 $g(x)$, 使其更好地适应了数据样本的分布. 但是, 该方法只优化了 SVR 常见三参数中的一个, 在面对一些复杂分布样本时, 仍不足以避免“过拟合”与“欠拟合”现象.

在 Cherkassky^[17]与 Hao^[21]所做工作的基础上, 本文提出一种柔性支持向量回归算法. 该算法首先将数据样本划分为多个区间, 然后为每个区间设置合理的回归参数, 进行有效的拟合, 最后对所有区间进行整合, 实现总体的函数逼近. 在该算法中, 回归问题的三个常见参数无需人为设定, 均由算法根据样本分布情况自动生成.

1 问题描述

给定训练样本集 $\{(x_1, y_1), \dots, (x_l, y_l)\}$, 支持向量回归的核心工作是求取一组合理的回归参数 p_0 以及最佳的分类超平面 (权重向量 w_0), 使得:

$$\begin{aligned} (p_0, w_0) &= \arg \min_{p, w} R_{\text{SRM}}(w, p) = \\ &\arg \min_{p, w} (R_{\text{ERM}} + \phi(w)) = \\ &\arg \min_{p, w} \left(\frac{1}{l} \sum_{i=1}^l \text{Loss}(y_i, f(x_i, w, p)) + \frac{1}{2}(w \cdot w) \right) \end{aligned} \quad (1)$$

其中, $p = \{C, \varepsilon, K(\cdot)\}$, C 为惩罚因子, ε 为不敏感因子, $K(\cdot)$ 为选定的核函数, $\text{Loss}(y_i, f(x_i, w, p)) = C_i \cdot |y_i - (\sum_{i=1}^l \beta_i K(x, x_i) + b)|_\varepsilon$. SVR 方法与传统回归方法的本质区别在于 SVR 不仅仅考虑了算法的学习能力, 更考虑了所得结果的 VC 置信度 (即泛化性能). 通常可通过构建如下拉格朗日式进行求解:

$$\min L(\alpha) = \frac{1}{2}(w, w) + C \sum_{i=1}^l (\xi_i + \xi_i^*) -$$

$$\begin{aligned} &\sum_{i=1}^l \alpha_i (y_i - (w, x_i) - b + \varepsilon + \xi_i) - \\ &\sum_{i=1}^l \alpha_i^* (-y_i + (w, x_i) + b + \varepsilon + \xi_i^*) - \\ &\sum_{i=1}^l (\beta_i \xi_i + \beta_i^* \xi_i^*) \end{aligned} \quad (2)$$

其中, $\alpha_i, \beta_i \geq 0$ 为拉格朗日乘子, ξ_i 为松弛变量, 其取值为

$$\begin{cases} \alpha_i, \beta_i > 0, & (x_i, y_i) \text{ 为支持向量} \\ \alpha_i, \beta_i = 0, & \text{否则} \end{cases} \quad (3)$$

$$\xi_i = \left| y_i - \left(\sum_{i=1}^l \beta_i K(x, x_i) + b \right) \right|_\varepsilon \quad (4)$$

因此, 式 (1) 的对偶问题可表述为最大化如下二次型:

$$\begin{aligned} W(\alpha) &= - \sum_{i=1}^l \varepsilon (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) - \\ &\frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(x_i, x_j) \end{aligned} \quad (5)$$

约束条件为

$$\begin{aligned} \sum_{i=1}^l \alpha_i^* &= \sum_{i=1}^l \alpha_i, \\ 0 &\leq \alpha_i \leq C, \quad 0 \leq \alpha_i^* \leq C, \quad i = 1, \dots, l \end{aligned} \quad (6)$$

本文中核函数始终采用径向基函数 (Radial basis function, RBF) 核函数:

$$K(x_i, x_j) = e^{-\frac{\|x-x'\|^2}{2\sigma^2}} \quad (7)$$

其中, σ 为核函数中的主要参数. 因此, 回归参数可写为 $p: \{\varepsilon, \sigma, C\}$.

注 1. 参数 ε, σ, C 极大地影响了式 (5) 的优化过程, 进而决定了支持向量的数目. 而支持向量则为勾勒分布函数提供有用信息. 当支持向量能够提供充足的信息时, 根据奥卡姆剃刀 (Occam's razor) 准则, 多余的支持向量应被删除. 2004 年 Cristianini 等^[22]在其专著中对支持向量与回归泛化能力的关系给出了如下描述.

引理 1. 假设在内积空间 X 中存在具有单位权重向量的有界实值线性函数 Γ . 对于 $X \times \{-1, 1\}$ 中的任意概率分布 D , 以概率 $1 - \delta$ 在 l 个随机样本

中, 所构建的最大边缘超平面发生错误的概率不超过:

$$err_{\varphi} \leq \frac{1}{l-d} \left(d \log \frac{el}{d} + \log \frac{l}{\delta} \right) \quad (8)$$

其中, $d = \#sv$ 为支持向量个数.

根据该引理, 支持向量的回归性能主要取决于支持向量的个数, 支持向量越少, 则回归的泛化性能越好. 而支持向量的个数又取决于回归参数, 因此回归参数对 SVR 的泛化性能有很大影响.

总体说来, 过多的支持向量会导致回归的过拟合, 即泛化性能差, 反之, 过少的支持向量又会导致回归欠拟合, 即学习性能差. SVR 参数设置的意义在于通过参数设置挑选出一组支持向量, 使回归在泛化性能及学习性能之间得到最佳折中, 既不过拟合, 又不欠拟合. 然而, 当样本分布较复杂时, 此类理想的参数往往很难被获取. 以图 1 为例, 图中样本根据分布的复杂度可被划分为 3 个区间 $X = \{X_A, X_B, X_C\}$, 在 A 和 C 区间中, 样本分布较简单, 需要的支持向量较少, 而在 B 中, 样本分布相对复杂, 需要较多支持向量为回归提供有效信息.

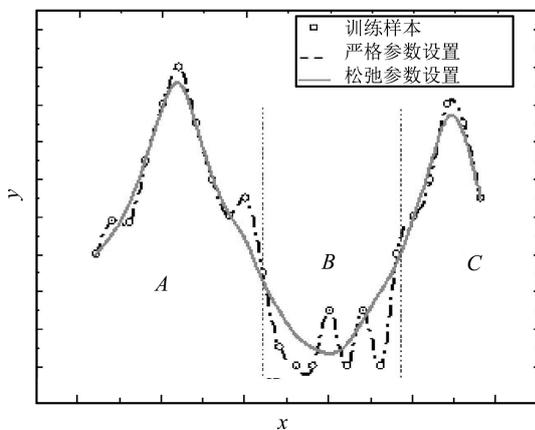


图 1 SVR 参数设定的困境
Fig. 1 Dilemma of SVR parameter setting

如果回归参数 p_1 选取得较松弛, 支持向量数较少, 则回归将有很好的泛化性能, 但是在 B 区间无法实现有效的学习; 反之, 如果参数选取得较严格, 支持向量数较多, 回归虽然在 B 区间实现了有效学习, 但在 A 区间和 C 区间却陷入了过拟合. A 区间和 C 区间对于支持向量个数的要求与 B 区间迥异, 因此无法获取一组固定的参数同时满足所有样本区间的需要. 采用传统的固定参数, 使得回归必然陷入过拟合或欠拟合.

为克服参数设置存在的上述矛盾, Hao 提出了一种参数不敏感模型 (Par- v -SVR). 该模型采用一个能够根据当前数据分布而自动调节的变量 $g(x)$

来取代传统固定的参数 ε . 它将式 (1) 进行了如下改写:

$$(p_0, w_0) = \arg \min_{p,w} R(w, p) = \arg \min_{p,w} \int_{T_0}^{T_k} dLoss(y, f(x, w, g(x)))p(x, y)dx dy \quad (9)$$

其中, $p : \{\varepsilon = g(x), \sigma, C\}$, 损失风险函数为

$$Loss_i = \left| y_i - \left(\sum_{i=1}^l \beta_i K(x, x_i) + b \right) \right|_{g(x_i)} = \begin{cases} 0, & \text{若 } \left| y_i - \left(\sum_{i=1}^l \beta_i K(x, x_i) + b \right) \right| \leq g(x_i) \\ \left| y_i - \left(\sum_{i=1}^l \beta_i K(x, x_i) + b \right) \right| - g(x_i), & \text{否则} \end{cases} \quad (10)$$

其中, $g(x) = (c \cdot \phi(x)) + d$ 可通过如下拉格朗日式进行求解:

$$L = \frac{1}{2} \|w\|^2 + C \left(\nu \cdot \left(\frac{1}{2} \|c\|^2 + d \right) \right) + \frac{1}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) - \sum_{i=1}^l \alpha_i [(w \cdot \phi(x_i) + b) + (c \cdot \phi(x_i) + d) - y_i + \xi_i] - \sum_{i=1}^l \alpha_i^* [-(w \cdot \phi(x_i) + b) + (c \cdot \phi(x_i) + d) + y_i + \xi_i^*] - \sum_{i=1}^l \beta_i \xi_i - \sum_{i=1}^l \beta_i^* \xi_i^* \quad (11)$$

该模型的主要贡献在于其参数设定的柔性思想: 参数不再是固定值, 而是随着样本分布的变化而变化. 然而需要指出的是, SVR 通常存在三个参数, 该模型只考虑了其中一个, 对于特定实际问题而言, 该模型尚不能完全胜任. 因此, 本文提出了一种柔性支持向量回归算法, 该方法将样本按照分布复杂度划分为多个区间, 然后为每个区间设置了不同的回归参数. 传统 SVR 中的固定参数 $p : \{\varepsilon, \sigma, C\}$ 被改写为一组能自我调整的参数向量:

$$\begin{cases} p^* = \{(\varepsilon_1, \sigma_1, C_1), (\varepsilon_2, \sigma_2, C_2), \dots, (\varepsilon_k, \sigma_k, C_k)\} \\ \varepsilon_i = g_1(T_i), \sigma_i = g_2(T_i), C_i = g_3(T_i) \end{cases} \quad (12)$$

其中, k 为区间个数, $T_i, (\varepsilon_i, \sigma_i, C_i)$ 为第 i 个区间中的训练样本及回归参数.

2 柔性支持向量回归

2.1 柔性支持向量回归的基本思想

将 Hao 的工作进行直接的扩展, 即令 $C = c(x_i)$, $\varepsilon = g(x_i)$, $\sigma = s(x_i)$ 时, 回归需解决如下 Lagrangian 式:

$$\begin{aligned} \min L(\alpha) = & \frac{1}{2}(w, w) + c(x_i) \sum_{i=1}^l (\xi_i + \xi_i^*) - \\ & \sum_{i=1}^l \alpha_i (y_i - (w, x_i) - b + g(x_i) + \xi_i) - \\ & \sum_{i=1}^l \alpha_i^* (-y_i + (w, x_i) + b + g(x_i) + \xi_i^*) - \\ & \sum_{i=1}^l (\beta_i \xi_i + \beta_i^* \xi_i^*) \end{aligned} \quad (13)$$

其中

$$\xi_i = \left| y_i - \left(\sum_{i=1}^l \beta_i \frac{\|x - x_i\|^2}{2s(x_i)} + b \right) \right|_{g(x_i)} \quad (14)$$

该 Lagrangian 式在求解过程中存在过多的变量, 计算量大、不具备工程可行性. 因此, 参考 Hao 的变量参数思想及 Cherkassky 的经验公式, 我们提出了柔性支持向量回归 (Flexible support vector regression, F-SVR) 方法. 该方法的主要思路为: 根据数据分布的复杂度将训练样本划分为多个区间, 针对不同区间, 生成不同的回归参数.

如图 2 所示, 柔性支持向量回归首先将样本按照数据分布的复杂度划分成多个区间. 针对分布复杂的区间, F-SVR 给定严格的回归参数; 而当分布较简单时, F-SVR 则生成松弛的参数. F-SVR 生成一组回归参数 $p^* = \{p_1^*, p_2^*, \dots, p_k^*\}$ 用于最小化式 (15):

$$\begin{aligned} R(w, p) = & \iint_{T_1} L(y, f(x, w, p_1)) p(x, y) dx dy + \\ & \iint_{T_2} L(y, f(x, w, p_2)) p(x, y) dx dy + \dots + \\ & \iint_{T_k} L(y, f(x, w, p_k)) p(x, y) dx dy \end{aligned} \quad (15)$$

定理 1. 式 (15) 的最小化问题可通过二次规划 (Quadratic programming, QP) 进行求解.

证明. 假设训练样本可被分为两部分: $(x_i, y_i)_{i=1}^q$ 和 $(x_i, y_i)_{i=q+1}^l$, $p = \{C, \sigma, \varepsilon\}$ 为回归参数. 此时, 式 (15) 的最小化问题可写为

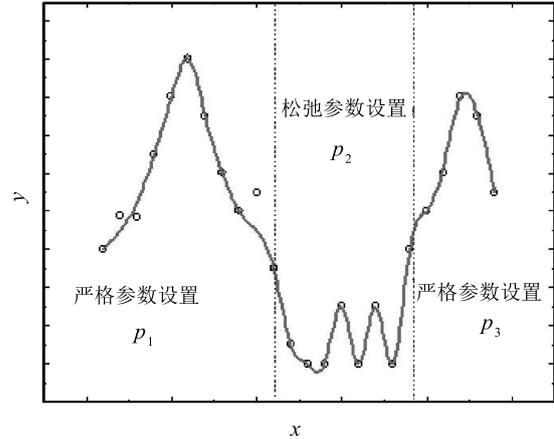


图 2 F-SVR 基本思想

Fig. 2 Basic idea of proposed F-SVR

$$\begin{aligned} \min & \frac{1}{2}(w, w) + C_1 \left(\sum_{i=1}^q \xi_i^* + \sum_{i=1}^q \xi_i \right) + \\ & C_2 \left(\sum_{i=q+1}^l \xi_i^{*2} + \sum_{i=q+1}^l \xi_i^2 \right) \\ \text{s.t.} & y_i - (w, x_i) - b \leq \varepsilon + \xi_i^* \\ & (w, x_i) + b - y_i \leq \varepsilon + \xi_i \\ & \xi_i^* \geq 0, \xi_i \geq 0 \end{aligned} \quad (16)$$

式 (16) 的 Lagrangian 式为

$$\begin{aligned} L(w, \xi^*, \xi, \alpha^*, \alpha, \gamma^*, \gamma) = & \frac{1}{2}(w, w) + C_1 \left(\sum_{i=1}^q \xi_i^* + \sum_{i=1}^q \xi_i \right) + \\ & C_2 \left(\sum_{i=q+1}^l \xi_i^{*2} + \sum_{i=q+1}^l \xi_i^2 \right) - \\ & \sum_{i=1}^l \alpha_i [y_i - w \cdot x_i - b + \varepsilon + \xi_i] - \\ & \sum_{i=1}^l \alpha_i^* [w \cdot x_i + b - y_i + \varepsilon + \xi_i^*] - \\ & \sum_{i=1}^l (\gamma_i^* \xi_i^* + \gamma_i \xi_i) \end{aligned} \quad (17)$$

对式 (17) 求偏导, 可得:

$$\begin{aligned} \frac{\partial L}{\partial w} = & w + \sum_{i=1}^l \alpha_i x_i - \sum_{i=1}^l \alpha_i^* x_i = 0 \\ \frac{\partial L}{\partial b} = & \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \end{aligned}$$

$$\frac{\partial L}{\partial \xi_i} = \begin{cases} C_1 - \alpha_i - \gamma_i, & 1 \leq i \leq q \\ 2C_2\xi_i - \alpha_i - \gamma_i, & q < i \leq l \end{cases} = 0$$

$$\frac{\partial L}{\partial \xi_i^*} = \begin{cases} C_1 - \alpha_i^* - \gamma_i^*, & 1 \leq i \leq q \\ 2C_2\xi_i^* - \alpha_i^* - \gamma_i^*, & q < i \leq l \end{cases} = 0 \quad (18)$$

将式 (18) 所得结果代入式 (17), 得:

$$L(\alpha, \alpha^*) = -\varepsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)(x_i \cdot x_j) - \sum_{i=q+1}^l C_2(\xi_i^2 + \xi_i^{*2}) \quad (19)$$

因此, 式 (16) 的对偶问题为

$$\max -\varepsilon \sum_{i=1}^l (\alpha_i^* + \alpha_i) + \sum_{i=1}^l y_i (\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^l (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)(x_i \cdot x_j) - \sum_{i=q+1}^l \frac{1}{4C_2} (\alpha_i^2 + \alpha_i^{*2})$$

s.t. $\sum_{i=1}^l (\alpha_i^* - \alpha_i) = 0$
 $0 \leq \alpha_i^* \leq C_i, 0 \leq \alpha_i \leq C_i \quad (20)$

其中, $C_i = \begin{cases} C_1, & 1 \leq i \leq q \\ C_2, & q + 1 \leq i \leq l \end{cases}$. 由于 $\alpha \cdot \alpha^* \equiv 0$, 式 (20) 可写为如下形式:

$$\min \frac{1}{2} (\alpha - \alpha^*)^T Q (\alpha - \alpha^*) + y^T (\alpha - \alpha^*) + \varepsilon e^T (\alpha + \alpha^*) - (\alpha - \alpha^*)^T v (\alpha - \alpha^*) \quad (21)$$

其中, $v = [0, \dots, \frac{1}{4}C_{q+1}^{-1}, \dots, \frac{1}{4}C_l^{-1}]$, $Q = K(x_i, x_j)$, e 为单位矢量. 因此, 回归过程可更进一步写为如下 QP 问题形式:

$$\min : \frac{1}{2} [\alpha^T, (\alpha^*)^T] \begin{bmatrix} D & -D \\ -D & D \end{bmatrix} \begin{bmatrix} \alpha \\ \alpha^* \end{bmatrix} + c^T \begin{bmatrix} \alpha \\ \alpha^* \end{bmatrix}$$

s.t. $z^T \begin{bmatrix} \alpha \\ \alpha^* \end{bmatrix} = 0, 0 \leq \alpha_i \leq C_i, 0 \leq \alpha_i^* \leq C_i \quad (22)$

其中, $D = Q - v$, $c = [\varepsilon e + y, \varepsilon e - y]$, $z_i = \begin{cases} 1, & i = 1, 2, \dots, q \\ -1, & i = q + 1, \dots, l \end{cases}$. 而此类二次规划问题可通过“活动集 (Active set)”法进行求解^[23].

2.2 柔性支持向量回归的基本流程

F-SVR 方法的基本流程如图 3 所示, 其细节将在后文详细介绍.

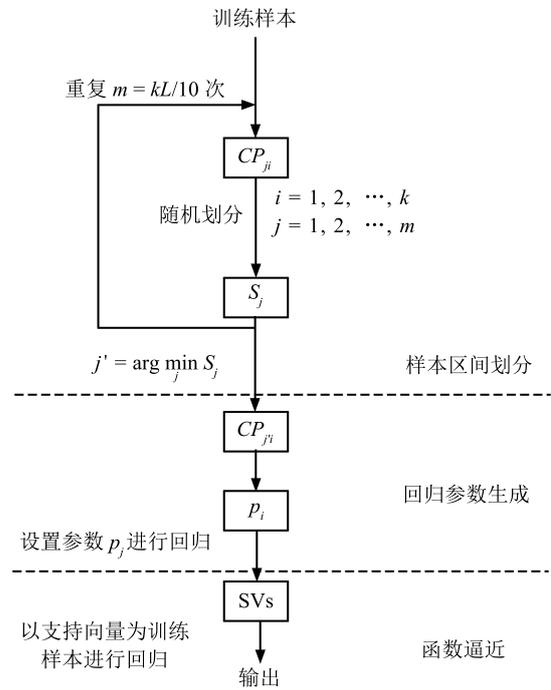


图 3 F-SVR 流程图

Fig.3 The flowchart of F-SVR

定义 1. CP 为区间复杂度评估函数; 给定区间样本 $(x_i, y_i)_{i=1}^l$, 式 (23) 可用于评估分布的复杂度:

$$CP = \frac{\sum_{i=1}^{l-1} \frac{|A_i|}{l-1}}{\sum_{i=1}^{l-2} \frac{\cos \theta_i}{l-2}} = \frac{l-2}{l-1} \cdot \frac{\sum_{i=1}^{l-1} |A_i|}{\sum_{i=1}^{l-2} \cos \theta_i} \quad (23)$$

其中, $A_i = (x_{i+1}, y_{i+1}) - (x_i, y_i)$, $\cos \theta_i = \frac{|A_i \cdot A_{i+1}|}{|A_i| \cdot |A_{i+1}|}$.

如图 4 所示, A_i 代表样本 (x_i, y_i) 与 (x_{i+1}, y_{i+1}) 之间的距离, 而 θ_i 为矢量 A_i 与 A_{i+1} 之间的夹角. $\sum_{i=1}^{n-1} |A_i|$ 代表了样本分布的密度, 而 $\sum_{i=1}^{n-2} \cos \theta_i$ 代表了样本的变化趋势.

通常说来, 样本间的密度越大, 变化趋势越简单, 则样本分布的复杂度越低, 回归参数选取应越松弛. 式 (23) 综合考虑了样本的分布密度及变化趋势. CP 值越小, 则代表区间中样本分布越复杂, 应设置更严格的回归参数. 如图 5(a) 所示, 当区间中样本

分布的密度相同时, CP 能够很好地考虑到样本分布趋势, 较为平滑的曲线获得更高的 CP 值; 而在图 5 (b) 中, 样本的分布趋势相同, 但分布的密度不同, 分布密度更高的曲线获得较高 CP 值. 在回归的过程中, 该曲线将获得更松弛的回归参数, 降低了噪声对回归的影响.

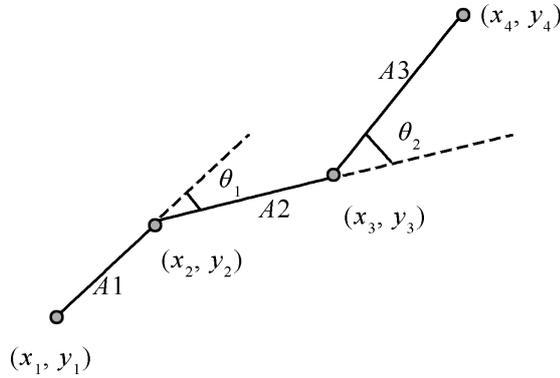


图 4 复杂度估计

Fig. 4 The estimation of complexity

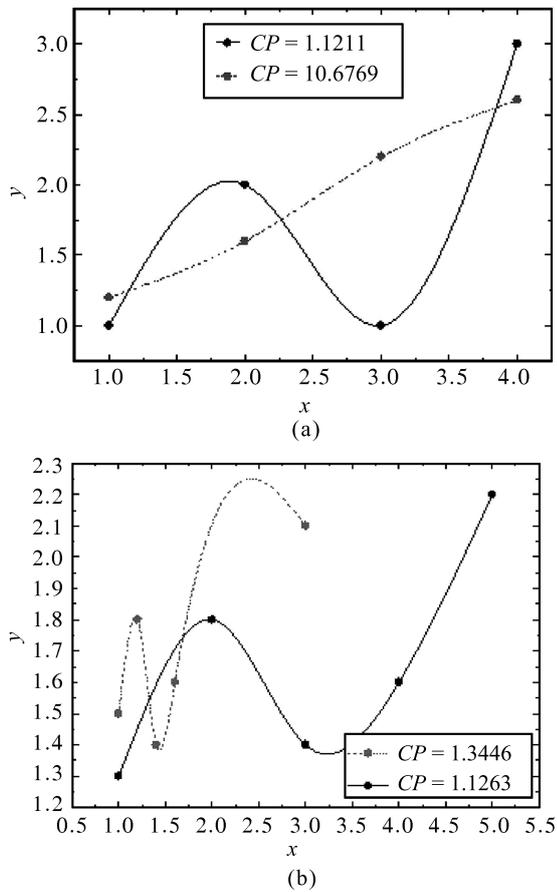


图 5 不同样本分布条件下的 CP 值

Fig. 5 CP s with different distributions

定义 2. 假设训练样本被划分为 k 个区间, 每个区间的复杂度为 $CP_i, i = 1, 2, \dots, k$, 式 (24) 用于评价当前区间划分的质量:

$$S = \sum_{i=1}^k \frac{-CP_i}{\sum_{j=1}^k CP_j} \log \frac{CP_i}{\sum_{j=1}^k CP_j} \quad (24)$$

将训练样本随机划分 m 次, 我们采用具有最小 S 值的区间划分作为理想区间划分:

$$j^* = \arg \min_j S_j, j = 1, 2, \dots, m \quad (25)$$

其中, $m = kl/10, l$ 为训练样本个数.

式 (24) 参考了信息熵的概念. 样本被划分之后, 区间之间复杂度差异越大, 则该划分所得到的 S 值越小. 以图 6 为例, 图 6 (b) 中左边区域的分布要比图 6 (a) 中复杂, 与此同时, 图 6 (b) 中右边区域的分布比图 6 (a) 中更平滑, 可认为图 6 (b) 中的划分要优于图 6 (a). 采用式 (24) 对图 6 (a) 和图 6 (b) 两图中的区间划分进行评价, 得:

$$S(a) = -\frac{1.5}{2.5} \lg \frac{1.5}{2.5} - \frac{1}{2.5} \lg \frac{1}{2.5} = 0.6730$$

$$S(b) = -\frac{2}{2.5} \lg \frac{2}{2.5} - \frac{0.5}{2.5} \lg \frac{0.5}{2.5} = 0.5004 \quad (26)$$

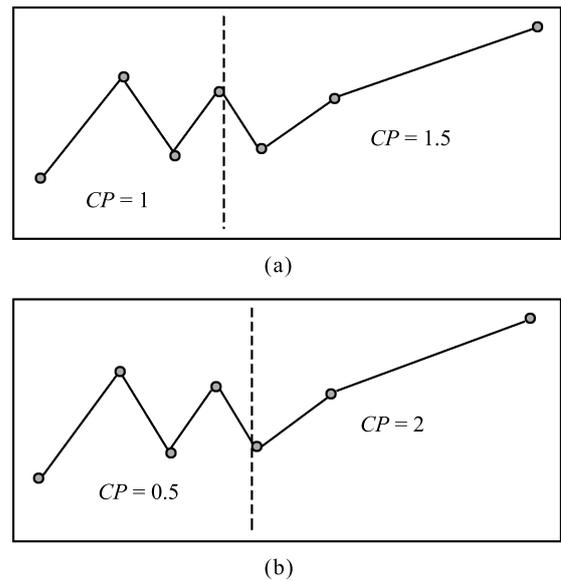


图 6 最佳区间划分选择

Fig. 6 Selecting the best division

根据式 (26) 的评估结果, 图 6 (b) 中区间划分将被选用.

定义 3. p_i 为第 i 个区间中样本的回归参数, 该参数由三个变量 ε, C, σ 组成. 当获取最佳区间划

分 j^* 及该划分中各区间的复杂度 $CP_{j^*} = \{CP_{j^*1}, CP_{j^*2}, \dots, CP_{j^*k}\}$ 后, 部分参照 Cherkassky 等的研究成果, 如下经验公式用以生成各区间中的回归参数:

$$\varepsilon_i = \frac{0.5Std^2(T_i)}{CP_{j^*i}} \quad (27)$$

$$C_i = \frac{1000CP_{j^*i}}{\sum_{i=1}^k CP_{j^*i}} \quad (28)$$

$$\sigma_i = \frac{5}{CP_{j^*i}} \quad (29)$$

2.3 采用所选支持向量进行回归

给定训练样本 $(x_i, y_i)_{i=1}^l$, 其中有 m 个样本被选为支持向量 (SVs), 则回归问题

$$f(x) = \sum_{i=1}^l \beta_i K(x, x_i) + \beta_0 \quad (30)$$

可采用如下形式进行逼近:

$$f(x) = \sum_{i=1}^m \gamma_i K(x, SV_i) + \gamma_0 \quad (31)$$

式 (3)~(6) 及式 (30) 和式 (31) 表明回归过程中, 仅有支持向量 SVs 发挥作用, 而非所有训练样本. 因此, F-SVR 意图寻找到充分而无冗余的支持向量对每个区间进行描述. 图 7 (a)~7 (c) 中解释了如何采用所选支持向量进行回归, 图 7 (d) 则展示了 F-SVR 的拟合效果.

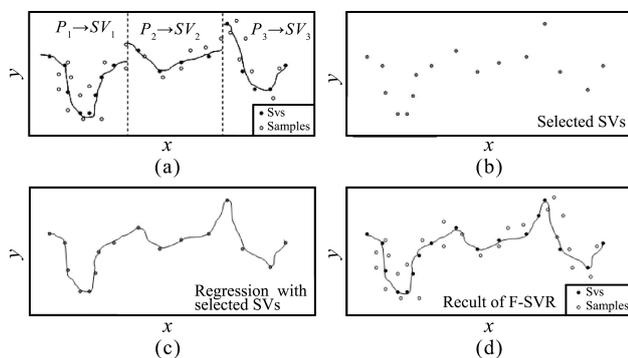


图 7 采用 SVs 进行回归
Fig.7 Regression with selected SVs

F-SVR 具体实现过程如下:

步骤 1. 在各区间选取支持向量. 样本被划分为 k 个区间, 每个区间都具有不同的复杂度 CP . 根据 CP 值, 我们可以为每个区间生成特定的回归参

数 p . 采用参数对指定区间进行回归, 可以得到支持向量 SVs (如图 7 (a)).

步骤 2. 生成新的训练样本集. 设 TS_i 为第 i 个区间中所选取的支持向量, 我们将所有支持向量提取出来, 并构建出新的训练样本集 $SVs = \{TS_1, TS_2, \dots, TS_k\} = \{SV_j\}_{j=1}^m$ (如图 7 (b)).

步骤 3. 函数逼近. 根据式 (31), 令 SVs 为训练样本, 设置严格回归参数, 对样本分布进行函数拟合 (如图 7 (c)).

2.4 k 值设定

F-SVR 在函数拟合时, 首先需要将样本划分为多个区间. 而如何选择区间数 “ k ” 是该方法所必须面对的一个问题. 一般地, k 值越大, 则参数变化越多, 回归过程也越灵活. 但是, 设置过大的 k 值, 同样会带来计算量的增加. 因此, 在 k 值选取的过程中, 需要对计算时间及回归性能之间进行权衡. 对于大多数情况而言, $k = 5$ 已经足以胜任. 针对划分空间数 k 值问题, 本文给出如下解决方法. 设 F-SVR 将样本划分为 k 个区间, $Ns(k)$ 为 F-SVR 得到的支持向量数, Y 和 Y_k 分别为系统的实际输出和拟合函数的输出. 给定阈值 t , 最佳区间数 k^* 为

$$k^* = \arg \min_k Ns(k)$$

$$\text{s.t. } \frac{\sqrt{(Y_k - Y)^2}}{\|Y\|} \leq t$$

3 实验

3.1 人工数据实验

我们设计了如下一组复杂分布的函数用于验证 F-SVR 的函数逼近能力:

$$y_1 = (x - 0.5)^2 + 4 \sin(3x^2) + x$$

$$y_2 = 4x(1 - x)[2 \sin(30x + 24) + 3]$$

$$y = \frac{1+x}{2}y_1 + \frac{1-x}{2}y_2, \quad x \in [-1, 1] \quad (32)$$

在 $x \in [-1, 1]$ 范围中, 等间抽取 600 个数据样本, 如图 8 所示, Y 函数在起始阶段分布较为复杂, 而在中后期分布较为简单.

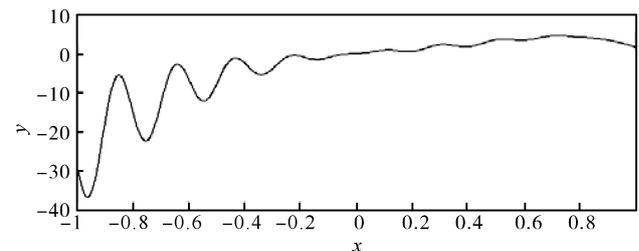


图 8 给定函数的样本分布情况
Fig.8 Sample distribution for given function

3.1.1 最佳区间数设定

采用 F-SVR 进行函数逼近, 首先需要为 F-SVR 设置一个合理的“ k ”值. 实验中采用支持向量的个数来衡量回归的泛化能力, 支持向量越少, 则回归的泛化性能越好; 同时采用函数“ R ”来衡量回归的学习能力, 如式 (34), R 值越小, 则回归的学习能力越好:

$$R = \frac{\sqrt{(Y_k - Y)^2}}{\|Y\|} \quad (33)$$

令 $k = 2, 3, 4, 5$, 实验分别调研了各种取值条件下, F-SVR 的回归性能, 如表 1 所示.

表 1 F-SVR 在不同“ k ”值下的性能
Table 1 F-SVR Performance with different k

区间数 (k)	SVs 个数 ($N_s(k)$)	学习性能 (R)
2	140	0.0617
3	145	0.0603
4	148	0.0665
5	143	0.0617

给定阈值 $t = 0.1$, 根据上文所述 k 值选取原则, 得到最佳区间数 $k^* = \arg \min N_s(k) = 2$ (此分区在满足回归学习性能的同时, 具备最好的泛化性能).

图 9 记录了 k 取不同值情况下, F-SVR 对训练样本的区间划分情况. 在全部 4 幅图中, F-SVR 均能有效地根据样本分布复杂度实现区间划分. 而当 $k = 2$ 时, 如图 9(a) 所示, 区间之间的差异性最明显, 该结论与理论估计相吻合.

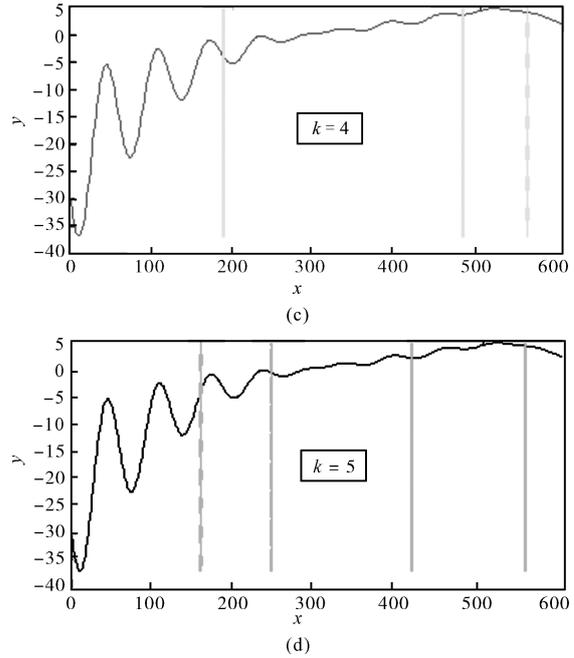
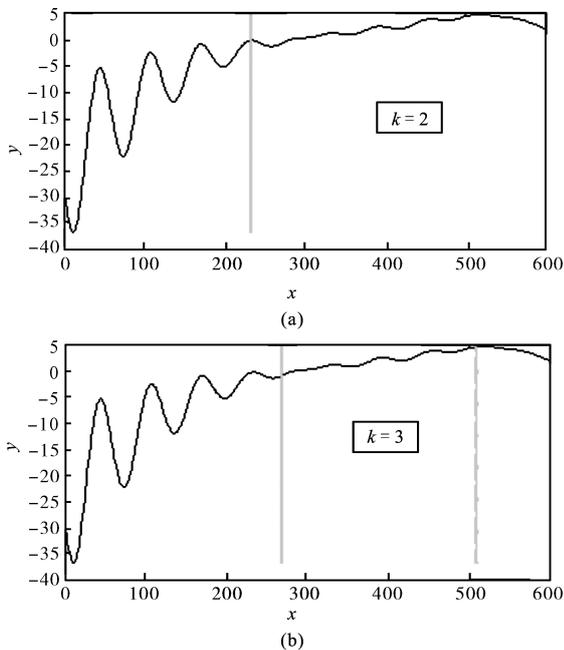


图 9 不同“ k ”值条件下 F-SVR 对样本区间的划分
Fig. 9 Divisions made by F-SVR with different k

3.1.2 对比实验

在对比实验中, 我们对人工数据加入噪声 (信噪比 $SNR = 30 \text{ dB}$), 使其分布更接近实际工程数据. 首先, 经典支持向量回归 (C-SVR) 被用于拟合输入输出函数^[24-26]. 在该组实验中, 我们将 C-SVR 的两个参数固定, 而第三个参数进行单独调整. 其回归表现如图 10 所示.

在图 10(a) 和图 10(b) 中, 由于固定的两个参数未能合理设置, 第三个参数的优化不能显著提高函数逼近能力. 这也同样证明了, 在 SVR 参数优化过程中, 对单个参数进行寻优并不能确保回归性能得到提高, 对三参数同时进行寻优才是正确的解决途径.

在图 10(c) 中, 对核参数 σ 的调整显著增加了 C-SVR 的学习能力, 使得 C-SVR 能够对函数进行充分的逼近, 但是在函数逼近的同时, 该方法陷入了过拟合. 给定严格的回归参数 $p : \{\epsilon = 0.1, C = 1000, \sigma = 0.003\}$, 600 个训练样本中有 561 个被选作支持向量.

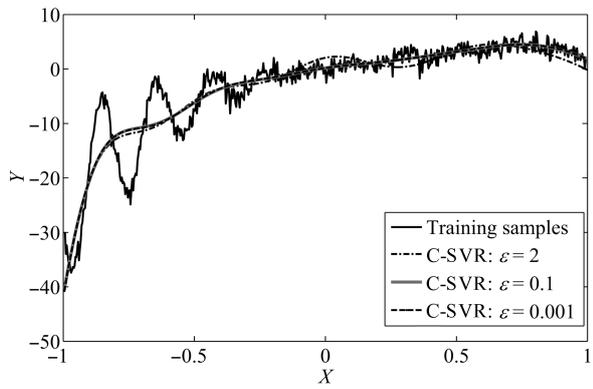
同时, 著名的最小二乘支持向量回归 (Least square support vector regression, LS-SVR), 以及 Hao 等提出的 Par- v -SVR 方法也被用于该样本集的函数逼近.

如图 11 所示, 给定回归参数如下: LS-SVR: $\gamma = 10, \sigma^2 = 0.2$; Par- v -SVR: $\sigma = 0.3, C = 1000, v = 0.1$, 其中 v 为回归不敏感性控制参数. 在样本分布的中后部分, 两者都能对函数进行有效拟合. 而在

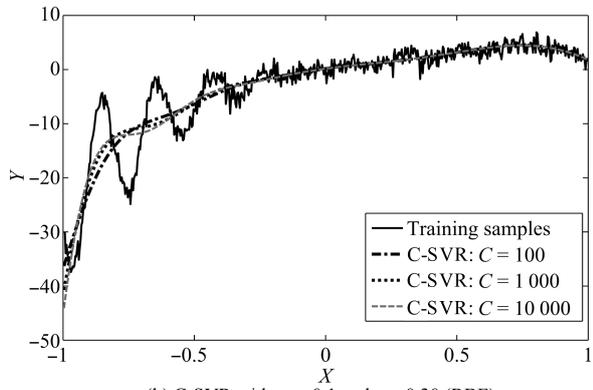
样本的起始阶段, 由于分布比较复杂, 两者都未能进行充分学习.

在图 12 中, 采用 F-SVR 对该数据集进行函数逼近. 设置 “ $k = 2$ ”, F-SVR 成功地将训练样本分为两个区间, 并各自给出回归参数:

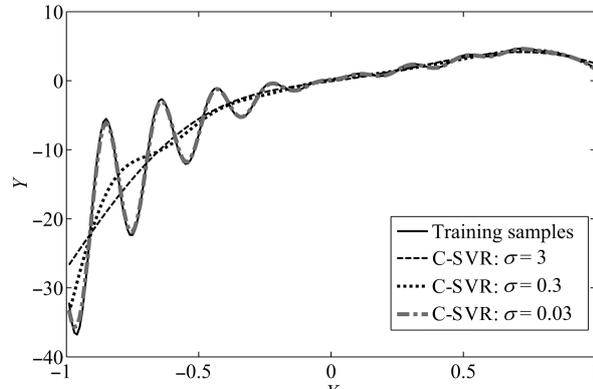
$$\begin{aligned}
 p1 : \{ \varepsilon = 0.1753, \sigma = 8.6894, C = 513.0063 \} \\
 p2 : \{ \varepsilon = 0.9813, \sigma = 9.1535, C = 486.9937 \}
 \end{aligned}
 \tag{34}$$



(a) C-SVR with $\sigma = 0.3$ and $C = 1000$ (RBF)



(b) C-SVR with $\varepsilon = 0.1$ and $\sigma = 0.30$ (RBF)



(c) C-SVR with $\varepsilon = 0.3$ and $C = 1000$ (RBF)

图 10 单参数调节时 C-SVR 对函数的拟合
Fig. 10 C-SVR tuned by single parameter

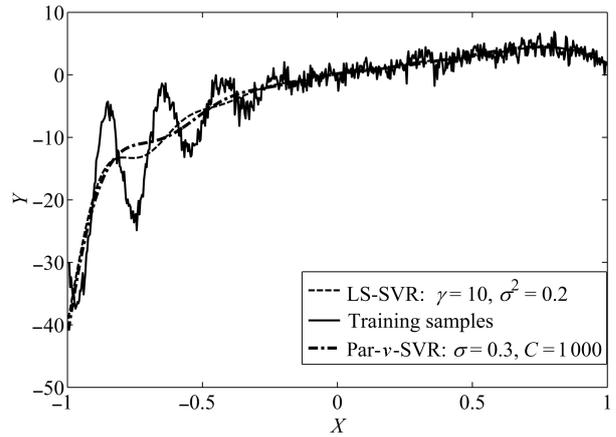


图 11 采用 LS-SVR 及 Par-v-SVR 进行函数拟合
Fig. 11 Regression using LS-SVR and Par-v-SVR

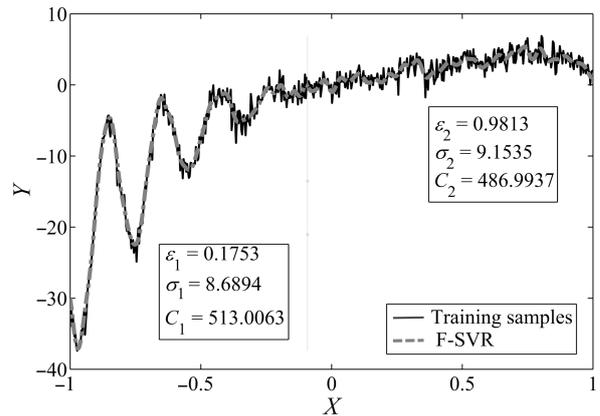


图 12 采用 F-SVR 进行函数拟合
Fig. 12 Performance of F-SVR

F-SVR 能够自动地生成回归参数. 与图 10 (a), 图 10 (b) 及图 11 相比, F-SVR 能对起始部分的复杂分布区间进行更为有效的拟合, 显示出更好的学习能力; 同时, 与图 10 (c) 相比, C-SVR 在回归中采用了 561 个支持向量, 陷入了过拟合, 而 F-SVR 仅仅采用了 361 个支持向量, 拥有更好的泛化能力; 实验表明 F-SVR 在保持学习性能的同时, 较传统方法具有更好的泛化性能.

3.2 故障检测中的应用

高频电源 (High frequency power supply, HFPS) 结构相对复杂, 其精准动态方程构建困难, 因此很难采用传统基于模型的方法进行故障检测^[27-30]. 在实际中, 通常采用极限值设定法 (Limit setting) 进行故障检测, 即为二次电流 (Secondary primary current, SPC) 设置一个合理的阈值, 如果二次电流超过阈值, 则认为系统故障, 反之, 则认为系统正常运行. 这种简单的判定方法很难胜任复杂非线性系统的需要, 通常存在误报率过高的问题.

因此, 数据驱动式故障诊断方法, 如 C-SVR, 被用以实现故障检测. 给定训练样本 $\{x, y\}_{i=1}^l$, 其中 x 为输入时间, y 为系统的二次电流值, l 为一个周期中的采样数. 对式 (1) 进行求解, 即可获取系统输入输出函数 $f(\cdot)$. 当给定测试样本 $\{x_t, y_t\}$ 时, 可通过分析残差 $r = y_t - \hat{y}_t = y_t - f(x_t)$ 实现故障检测.

然而, 支持向量回归对函数的逼近能力取决于回归参数的设置. 采用 SVR 进行故障检测, 需要工作人员具有足够的领域经验, 并能够根据经验设置出有效的回归参数. 更进一步, 一旦训练样本发生变化, 工作人员需第一时间对回归参数做出调整. 该方法对工作人员的技术水平要求过高, 且自动化程度较低, 加大了工作人员的工作强度. 因此, 本文将所提出的 F-SVR 方法用于高频电源的故障检测, 该方法无需人工设置参数, 能够根据数据分布自动地生成回归参数, 提高了支持向量回归故障诊断的工程实用性.

在本节中, 首先将 F-SVR 方法用于 HFPS 的故障检测, 通过实验验证其可行性. 然后, 将 F-SVR 方法与常规方法以及当前的一些改进方法做出对比实验, 验证该算法的优越性.

3.2.1 可行性验证

高频电源及其正常运行情况下的二次电流波形如图 13 所示. 首先, 需对正常运行状况的二次电流波形进行训练样本的提取. 如图 14 所示, 我们以抽样间隔 $50 \mu\text{s}$, 在第一个波谷区域提取出 320 个数据点作为训练样本.

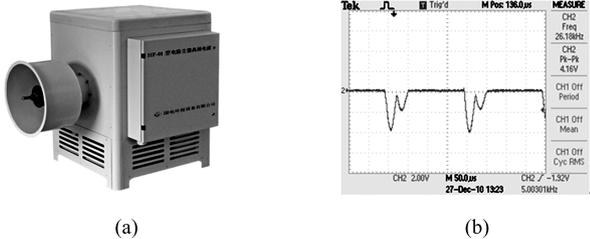


图 13 高频电源及其二次电流波形
Fig. 13 High frequency power supply and its secondary primary current

然后采用本文所提的 F-SVR 方法对训练样本进行学习, 对正常运行数据进行函数逼近. 回归过程中, k 值选取为 2, 所有回归参数由 F-SVR 自动生成, 函数拟合效果如图 15.

采集系统发生偏励磁故障时的波形作为测试样本集, 如图 16. 设 $\{x, y_f\}_{i=1}^l$ 为图 16 所提供的故障数据样本, 而系统正常运行状态数据样本由图 14 所提供. 进一步为残差分析设置阈值:

$$sd = \frac{\sqrt{\sum (y - y_f)^2}}{l} \approx 1.87$$

$$t = sd \times 0.7 \approx 1.3 \quad (35)$$

其中, sd 是故障数据与正常数据的平均距离, t 为所设定的阈值. 然后, 采用 F-SVR 方法对正常数据样本进行拟合, 计算当前输出与拟合函数输出之间的残差. 如图 17 所示, 测试实验中, 所提方法成功地实现了偏励磁故障的检测.

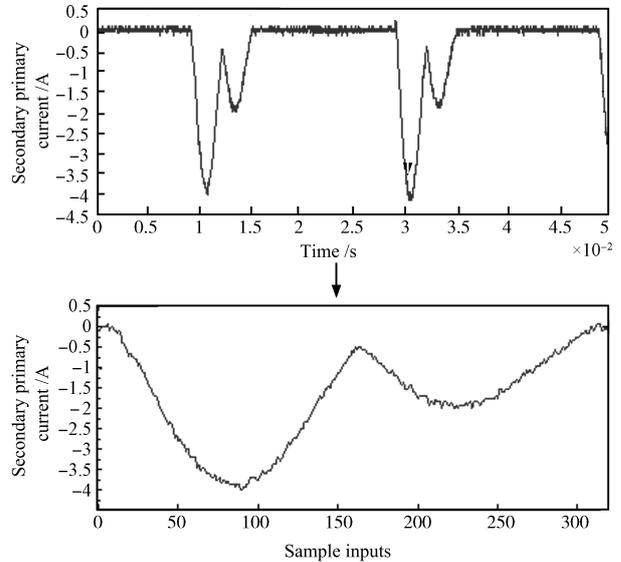


图 14 提取正常二次电流波形数据样本
Fig. 14 Extracting the normal secondary primary current

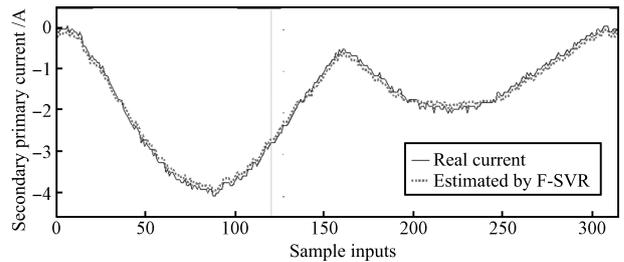


图 15 采用 F-SVR 对非线性函数进行逼近
Fig. 15 Approximating the nonlinear function using F-SVR

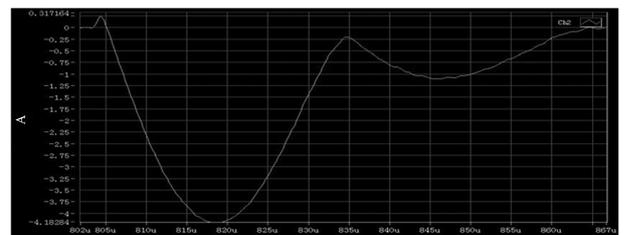


图 16 偏励磁故障的二次电流波形
Fig. 16 The secondary primary current performance of leaning excitation fault

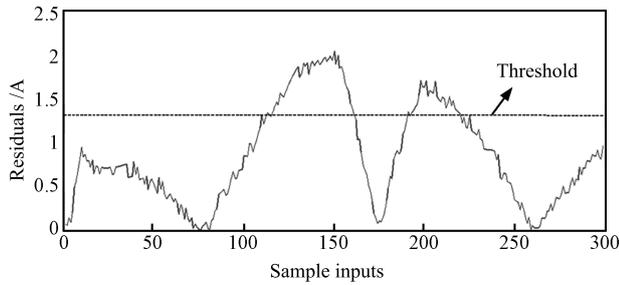


图 17 高频电源系统偏励磁故障的检测
Fig. 17 Fault identification of leaning excitation for HFPS

在本实验中, 所提基于 F-SVR 的故障检测方法在没有人工设定回归参数的情况下, 有效地实现了故障检测, 证实了所提方法的有效性.

3.2.2 性能对比实验

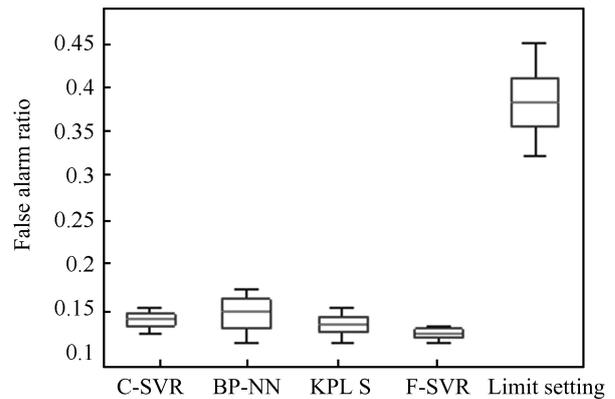
在本实验中, 我们用 F-SVR 方法分别与传统的极限值设定法 (Limit setting)、C-SVR 方法^[4]以及另外一些数据驱动方法, 包括 BP 神经网络 (BP-neural network, BP-NN)^[31] 和核偏最小二乘法 (Kernel partial least squares, KPLS)^[32-34] 做性能对比.

实验首先从正常运行数据集中选出 120 个样本, 其中 20 个样本用于函数逼近, 100 个样本用于求取各算法的故障虚警率 (False alarm ratio). 从故障数据集中选出 20 个样本, 用于测试各算法的故障漏报率 (Missed detection ratio). 假设实际操作人员缺乏数据驱动领域专业经验, 各检测方法的参数随机生成. 分别重复实验 20 次后, 5 种检测方法性能如图 18 所示.

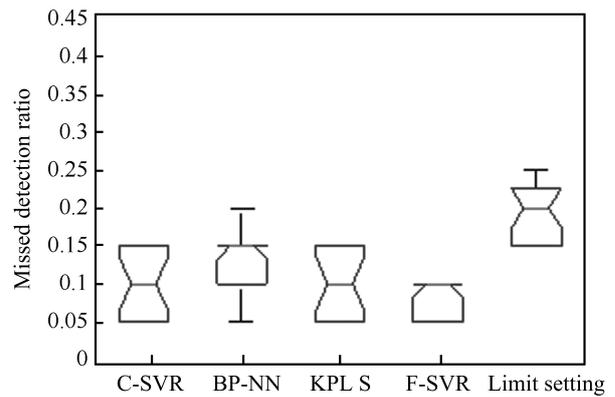
图 18 (a) 展示了五种检测方法的故障虚警率, 即正常样本被误判为故障样本的概率; 而图 18 (b) 展现了各种方法的故障漏警率, 即故障样本未被识别的概率. 在图 18 (a) 和图 18 (b) 中, 我们发现: 1) F-SVR 对应的值均低于其他方法; 2) F-SVR 的方差明显小于其他方法. 这意味着 F-SVR 拥有更准确的故障检测能力以及更佳的安全性. 该对比实验证实了所提方法的优越性.

4 结论

支持向量回归算法的参数设置缺乏被广泛接受的理论指导, 这将增大普通操作人员进行实际应用时的难度. 更进一步, 如第 1 节所述, 传统 SVR 参数设置方法在面临复杂分布样本时, 可能无法找到一组参数, 同时避免“过拟合”与“欠拟合”现象. 因此, 本文提出了一种柔性支持向量回归方法, 该方法能够根据样本分布复杂度自动调整回归参数, 使得参数不再以固定值的形式参与回归过程.



(a) False alarm ratio



(b) Missed detection ratio

图 18 各方法故障检测性能对比

Fig. 18 The comparisons of detecting performances for investigated approaches

采用自动调节的回归参数, F-SVR 方法在保持了算法学习能力的同时, 减少了支持向量的个数, 进而提高了算法的泛化性能. 算法的有效性首先通过一组复杂分布人工数据进行验证, 在该实验中, 常规方法均陷入“过拟合”与“欠拟合”的两难困境, 而 F-SVR 方法则通过在回归过程中不断调节自身参数, 有效地实现了函数拟合, 展现出算法的优越性. 更进一步, 我们将 F-SVR 方法应用至高频电源的偏励磁故障检测. 实验中, F-SVR 在避免了复杂参数设置的前提下, 有效地提高了故障检测的准确率, 证实了算法的有效性.

但是, 尽管 F-SVR 在回归过程中无需对传统的三个参数进行设定, 该方法在应用时引入了一个新的参数: 区间数“ k ”. 该参数的设置将影响算法的计算速度, 如何有效地选择 k 值是未来工作需要解决的一个问题. 同时, 本文将 F-SVR 方法成功应用至故障检测, 而如何采用 F-SVR 进行有效的故障隔离, 也将是我们进一步工作的重点.

References

- 1 Vapnik V N. *The Nature of Statistical Learning Theory*. Berlin: Springer-Verlag, 1995
- 2 Müller K R, Smola A, Rätsch G, Schölkopf B, Kohlmorgen J, Vapnik V. Predicting time series with support vector machines. In: Proceedings of the 7th International Conference on Artificial Neural Networks-ICANN'97. London, UK: Springer-Verlag, 1997. 999–1004
- 3 Yang H Q, Huang K Z, King I, Lyu M R. Localized support vector regression for time series prediction. *Neurocomputing*, 2009, **72**(10–12): 2659–2669
- 4 Clarke S M, Griebisch J H, Simpson T W. Analysis of support vector regression for approximation of complex engineering analyses. *Journal of Mechanical Design*, 2005, **127**(6): 1077–1088
- 5 Thukaram D, Khincha H P, Vijaynarasimha H P. Artificial neural network and support vector machine approach for locating faults in radial distribution systems. *IEEE Transactions on Power Delivery*, 2005, **20**(2): 710–721
- 6 Cherkassky V, Shao X H, Mulier F M, Vapnik V N. Model complexity control for regression using VC generalization bounds. *IEEE Transactions on Neural Networks*, 1999, **10**(5): 1075–1089
- 7 Vapnik V, Chapelle O. Bounds on error expectation for support vector machines. *Neural Computation*, 2000, **12**(9): 2013–2036
- 8 Chapelle O, Vapnik V, Bengio Y. Model selection for small sample regression. *Machine Learning*, 2002, **48**(1–3): 9–23
- 9 Schölkopf B, Bartlett P L, Smola A J, Williamson R C. Shrinking the tube: a new support vector regression algorithm. In: Proceedings of the 1998 Advances in Neural Information Processing Systems, 11. Cambridge: MIT Press, 1998
- 10 Schölkopf B, Smola A J, Williamson R C, Bartlett P L. New support vector algorithms. *Neural Computation*, 2000, **12**(5): 1207–1245
- 11 Kwok J T, Tsang I W. Linear dependency between ε and the input noise in ε -support vector regression. *IEEE Transactions on Neural Networks*, 2003, **14**(3): 544–553
- 12 Chang M W, Lin C J. Leave-one-out bounds for support vector regression model selection. *Neural Computation*, 2005, **17**(5): 1188–1222
- 13 Chapelle O, Vapnik V, Bousquet O, Mukherjee S. Choosing multiple parameters for support vector machines. *Machine Learning*, 2002, **46**(1–3): 131–159
- 14 Üstün B, Melssen W J, Oudenhuijzen M, Buydens L M C. Determination of optimal support vector regression parameters by genetic algorithms and simplex optimization. *Analytica Chimica Acta*, 2005, **544**(1–2): 292–305
- 15 Pai P F, Lin C S, Hong W C, Chen C T. A hybrid support vector machine regression for exchange rate prediction. *Information and Management Sciences*, 2006, **17**(2): 19–32
- 16 Tian W J, Tian Y. A new fuzzy identification approach using support vector regression and particle swarm optimization algorithm. In: Proceedings of the 2009 ISECS International Colloquium on Computing, Communication, Control, and Management, Sanya, China: IEEE, 2009. 86–90
- 17 Cherkassky V, Ma Y Q. Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 2004, **17**(1): 113–126
- 18 Farooq T, Guergachi A, Krishnan S. Knowledge-based green's kernel for support vector regression. *Mathematical Problems in Engineering*, 2010, **2010**:1–16
- 19 Zhang W F, Dai D Q, Yan H. Framelet kernels with applications to support vector regression and regularization networks. *IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics*, 2010, **40**(4): 1128–1144
- 20 Apolloni B, Malchiodi D, Valerio L. Relevance regression learning with support vector machines. *Nonlinear Analysis: Theory, Methods & Applications*, 2010, **73**(9): 2855–2867
- 21 Hao P Y. New support vector algorithms with parametric insensitive/margin model. *Neural Networks*, 2010, **23**(1): 60–73
- 22 Cristianini N, Shawe-Taylor J. *An introduction to Support Vector Machines*. Cambridge: Cambridge University Press, 2000
- 23 Bunch J R, Kaufman L. A computational method for the indefinite quadratic programming problem. *Linear Algebra and Its Applications*, 1980, **34**: 341–370
- 24 Song X F, Chen W M, Chen Y J P P, Jiang B. Candidate working set strategy based SMO algorithm in support vector machine. *Information Processing and Management*, 2009, **45**(5): 584–592
- 25 Yi Hui, Song Xiao-Feng, Jiang Bin, Wang Ding-Cheng. Support vector machine based on nodes refined decision directed acyclic graph and its application to fault diagnosis. *Acta Automatica Sinica*, 2010, **36**(3): 427–432
(易辉, 宋晓峰, 姜斌, 王定成. 基于结点优化的决策导向无环图支持向量机及其在故障诊断中的应用. *自动化学报*, 2010, **36**(3): 427–432)
- 26 Song X F, Chen W M, Jiang B. Sample reducing method in SVM based on K-closed sub-clusters. *International Journal of Innovative Computing Information and Control*, 2008, **4**(7): 1751–1760
- 27 Ge Z Q, Gao F R, Song Z H. Batch process monitoring based on support vector data description method. *Journal of Process Control*, 2011, **21**(6): 949–959

- 28 Zhou Dong-Hua, Hu Yan-Yan. Fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2009, **35**(6): 748–754
(周东华, 胡艳艳. 动态系统的故障诊断技术. *自动化学报*, 2009, **35**(6): 748–754)
- 29 Zhou Dong-Hua, Li Gang, Li Yuan. *Data-Driven Fault Diagnostic Techniques for Industrial Processes: Based on PCA and PLS*. Beijing: Science Press, 2011
(周东华, 李钢, 李元. 数据驱动的工业过程故障诊断技术——基于主元分析与偏最小二乘的方法. 北京: 科学出版社, 2011)
- 30 Jiang B, Staroswiecki M, Cocquempot V. Fault accommodation for nonlinear dynamic systems. *IEEE Transactions on Automatic Control*, 2006, **51**(9): 1578–1583
- 31 Maki Y, Loparo K A. A neural-network approach to fault detection and diagnosis in industrial processes. *IEEE Transactions on Control Systems Technology*, 1997, **5**(6): 529–541
- 32 Zhang Y W, Teng Y D, Zhang Y. Complex process quality prediction using modified kernel partial least squares. *Chemical Engineering Science*, 2010, **65**(6): 2153–2158
- 33 Zhang Y W, Chai T Y, Li Z M, Yang C Y. Modeling and monitoring of dynamic processes. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, **23**(2): 277–284
- 34 Zhang Y W, Zhou H, Qin S J, Chai T Y. Decentralized fault diagnosis of large-scale processes using multiblock kernel partial least squares. *IEEE Transactions on Industrial Informatics*, 2010, **6**(1): 3–10



易 辉 南京工业大学自动化与电气工程学院讲师. 分别于 2005 与 2012 年在南京航空航天大学自动化学院获取学士、博士学位. 主要研究方向为故障诊断, 健康管理与模式识别技术.
E-mail: yihui@njut.edu.cn
(**YI Hui** Lecturer at the College of Automation and Electronic Engineering,

Nanjing University of Technology. He received his bachelor and Ph.D. degrees from the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics in 2005 and 2012, respectively. His research interest covers fault diagnosis, health monitoring, and pattern recognition.)



宋晓峰 南京航空航天大学自动化学院教授. 主要研究方向为智能计算, 生物信息学. E-mail: xfsong@nuaa.edu.cn
(**SONG Xiao-Feng** Professor at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. His research interest covers intelligent computation and bioinformatics.)



姜 斌 南京航空航天大学自动化学院教授. 主要研究方向为故障诊断与容错控制. 本文通信作者.
E-mail: binjiang@nuaa.edu.cn

(**JIANG Bin** Professor at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. His research interest covers fault diagnosis and fault tolerant control. Corresponding author of this paper.)



刘宇芳 南京航空航天大学自动化学院博士生. 主要研究方向为智能控制及电气工程. E-mail: lyf_gdhh@163.com
(**LIU Yu-Fang** Ph.D. candidate at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. Her research interest covers intelligent control and electronic engineering.)



周智华 国电科学技术研究院高级工程师. 于 1989 年在华中科技大学获取学士学位. 主要研究方向为系统监控及电厂改造.

E-mail: zhouzhihua130@yahoo.com.cn
(**ZHOU Zhi-Hua** Senior engineer of the Guodian Science and Technology Research Institute. He received his

bachelor degree from Huazhong University of Science and Technology in 1989. His research interest covers system monitoring and enhancement for power stations.)