

自适应误差惩罚支撑向量回归机

陈晓峰^① 王士同^① 曹苏群^{①②}

^①(江南大学信息学院 无锡 214122)

^②(淮阴工学院机械系 淮安 223001)

摘要: 该文提出一种支撑向量回归机 AEPSVR。它首先用 ε -SVR 求得一个近似的支撑向量回归函数,在此基础上,引入一种新自适应误差惩罚函数,通过迭代,得到鲁棒的支撑向量回归机。该方法因以 ε -SVR 为基础,故可以应用各种求解 SVR 的优化算法。实验表明,该支撑向量回归机 AEPSVR 能显著地降低离群点的影响,具有良好的泛化性能。

关键词: 支撑向量回归; 离群点; 自适应误差惩罚

中图分类号: TP181

文献标识码: A

文章编号: 1009-5896(2008)02-0367-04

SVR with Adaptive Error Penalization

Chen Xiao-feng^① Wang Shi-tong^① Cao Su-qun^{①②}

^①(School of Information, Southern Yangtze University, Wuxi 214122, China)

^②(Department of Mechanical Engineering, Huaiyin Institute of Technology, Huaian 223001, China)

Abstract: A novel support vector regression method AEPSVR is proposed in this paper. First, an approximate regression function is obtained using ε -SVR method, and then a new adaptive error penalization function is introduced to enhance the robust performance of SVR such that a robust support vector regression is derived. Because the proposed AEPSVR here is based on ε -SVR, so various optimization methods for SVR can be used. Experimental results show that the proposed AEPSVR can reduce the affect of outliers, and have the very good generalization capability.

Key words: Support Vector Regression (SVR); Outlier; Adaptive Error Penalization (AEP)

1 引言

支撑向量回归机(SVR)是支撑向量方法在函数拟合与回归估计的应用^[1, 2]。支撑向量回归机在处理含有离群点数据时,拟合性能要受到离群点的影响。离群点与其他训练样本相比对应较大的训练误差,导致训练结果与没有离群点时相比会有很大变化。减小离群点的影响对构造鲁棒的支撑向量回归机有很重要的意义。

在支撑向量分类问题中,根据距离^[3],最小化“留一法”交叉验证的训练误差上界^[4],hinge 损失函数^[5],非线性的惩罚函数^[6]等减小离群点影响。在支撑向量回归问题中,文献[7]的方法是,首先用常规 SVR 得到一个近似的支撑向量回归函数,然后对目标函数加权,通过迭代得到优化结果。文献[8]的方法是用加权平方误差损失函数代替常规支撑向量回归方法中的 ε -不敏感函数。文献[9]的方法是首先用常规 SVR 得到一个有支撑向量的初始径向基函数网,再用鲁棒损

失函数调节网络参数。文献[10]研究了一种分为三段的代价函数,用 ε -不敏感函数计算低频变量的噪声代价,用平方误差函数计算样本检测误差代价,用线性函数限制离群点的影响。文献[11,12]提出基于证据框架的鲁棒支撑向量参数优选方法。

本文提出的 AEPSVR 支撑向量回归机算法,主要是通过引入一种新的代价函数消减离群点的影响。

2 自适应误差惩罚支撑向量回归机(AEPSVR)

2.1 ε -SVR

假定训练样本集为 $\{(x_1, y_1), \dots, (x_l, y_l)\} \subset R^N \times R$, x_i 为输入变量的值, y_i 为对应的输出值, N 为输入变量的维数, l 为训练样本数。在 ε -SVR 中,估计函数 $f(x)$,使得对于所有训练样本,有 $|f(x_i) - y_i| \leq \varepsilon (i = 1, \dots, l)$,且 $f(x)$ 要尽可能平滑。假设 $f(x)$ 为线性函数(可以通过核方法扩展到非线性情况),即 $f(x) = \langle w, x \rangle + b$,其中 $w \in R^N$, $b \in R$, $\langle \cdot, \cdot \rangle$ 代表内积。求函数 $f(x)$ 即可表述为如下求极小值问题:

$$\text{minimize } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

2006-07-20 收到, 2007-01-31 改回

2004 年教育部优秀人才支持计划(NCET-04-0496),模式识别国家重点实验室开放课题,南京大学软件新技术国家重点实验室开放课题,教育部重点科学研究项目(105087)和国防应用基础研究基金项目(A1420061266)资助课题

$$\text{s.t.} \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

其中正常量 C 为惩罚因子, 协调函数 $f(x)$ 的平滑性与训练精度。 $\xi_i^{(*)}$ (表示 ξ_i 或 ξ_i^*) 由下述 ε -不敏感损失函数计算:

$$|\xi|_\varepsilon = \begin{cases} 0, & |\xi| \leq \varepsilon \\ |\xi| - \varepsilon, & \text{其他} \end{cases}$$

上述问题可以通过 Lagrange 求极值方法转为如下的 Wolfe 对偶的二次规划问题:

$$\text{minimize} \begin{cases} -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \\ -\varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{cases}$$

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

待变量 w, b 可表示为

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (1)$$

$$\begin{aligned} \max\{-\varepsilon + y_i - \langle w, x_i \rangle \mid \alpha_i < C \text{ 或 } \alpha_i^* > 0\} &\leq b \\ \leq \min\{-\varepsilon + y_i - \langle w, x_i \rangle \mid \alpha_i > 0 \text{ 或 } \alpha_i^* < C\} &\quad (2) \end{aligned}$$

2.2 AEPSVR

构建鲁棒支撑向量回归机 AEPSVR 的关键在于构造合适的代价函数。为了减小离群点对回归的影响, 代价函数必须是有界的。此外, 代价函数应当具有合适的结构, 以方便求解二次规划对偶问题, 使得正则化参数能根据训练误差 $\xi_i^{(*)} (i = 1, \dots, l)$ 自动地进行调整, 本文称这种性质为自适应性。

本文引入一种新的代价函数 $\text{erf}(\xi, \sigma) = \frac{2}{\sqrt{\pi}\sigma} \int_0^\xi e^{-x^2/\sigma^2} dx$ (简称为 erf 函数) 来构建鲁棒支撑向量回归机 AEPSVR。erf 函数是有界函数。如图 1 所示, erf 函数是奇函数, 当 $\lim_{\xi \rightarrow +\infty} \text{erf}(\xi, \sigma) = 1$, 离群点对应的 ξ 值比较大, 但无论 ξ 多大,

erf 函数极限是 1, 因此, 用它做代价函数可以大大降低离群点的影响。参数 σ 调节 erf 函数的收敛速度, 当 σ 较小时, 代价函数收敛的速度更快。

以 ε -SVR 为基础, 重新建立的规划问题如下(下面的公式推导假定为 $f(x)$ 为线性, 可以通过核方法扩展到非线性情况):




图1 erf 函数

$$\text{minimize} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\text{erf}(\xi_i, \sigma) + \text{erf}(\xi_i^*, \sigma))$$

$$\text{s.t.} \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

其中正的常量 C 为惩罚因子, $\xi_i^{(*)}$ 由下述 ε -不敏感损失函数计算

$$|\xi|_\varepsilon = \begin{cases} 0, & |\xi| \leq \varepsilon \\ |\xi| - \varepsilon, & \text{其他} \end{cases}$$

自适应惩罚函数定义为

$$\text{erf}(\xi_i^{(*)}, \sigma) = \frac{2}{\sqrt{\pi}\sigma} \int_0^{\xi_i^{(*)}} e^{-\frac{x^2}{\sigma^2}} dx \quad (3)$$

用 Lagrange 求极值方法求解上述问题, 则有

$$\begin{aligned} L_p(w, b, \xi) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\text{erf}(\xi_i, \sigma) + \text{erf}(\xi_i^*, \sigma)) \\ &\quad - \sum_{i=1}^l \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) \\ &\quad - \sum_{i=1}^l \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x_i \rangle - b) \\ &\quad - \sum_{i=1}^l \mu_i \xi_i - \sum_{i=1}^l \mu_i^* \xi_i^* \end{aligned} \quad (4)$$

且 $\alpha_i^{(*)} \geq 0, \mu_i^{(*)} \geq 0 (i = 1, \dots, l)$ 。

根据 Kuhn-Tucker 条件, 将上式转为为对偶问题, 即为

$$\begin{aligned} \text{minimize} & -\frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \\ & - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \\ & + C \sum_{i=1}^l (\xi_i \text{erf}'(\xi_i, \sigma) - \text{erf}(\xi_i, \sigma)) \\ & + C \sum_{i=1}^l (\xi_i^* \text{erf}'(\xi_i^*, \sigma) - \text{erf}(\xi_i^*, \sigma)) \end{aligned} \quad (5)$$

且 $0 \leq \alpha_i^{(*)} \leq C \cdot \text{erf}'(\xi_i^{(*)}, \sigma), \xi_i^{(*)} \geq 0 (i = 1, \dots, l)$ 。

w, b 可表示为

$$w = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \quad (6)$$

$$\begin{aligned} \max\{-\varepsilon + y_i - \langle w, x_i \rangle \mid \alpha_i < C \text{ 或 } \alpha_i^* > 0\} &\leq b \\ \leq \min\{-\varepsilon + y_i - \langle w, x_i \rangle \mid \alpha_i > 0 \text{ 或 } \alpha_i^* < C\} &\quad (7) \end{aligned}$$

$$\text{erf}'(\xi_i^{(*)}, \sigma) = \frac{1}{\sqrt{\pi}\sigma} e^{-\frac{(\xi_i^{(*)})^2}{\sigma^2}} \quad (8)$$

由此, AEPSVR 转化为求解二次规划问题。正则化参数 $C_i (i = 1, \dots, l)$ 由 $\text{erf}'(\xi, \sigma)$ 根据训练误差 ξ 自适应调整。如图 2 所示, $\text{erf}'(\xi, \sigma)$ 随着误差 ξ 变大而迅速减小, 离群点对应的训练误差 ξ 远比非离群点大, 因此, 离群点对应的正则化参数 C_i 迅速降低, 离群点在训练中的影响也随之降低。




图 2 erf'(xi, sigma) 函数

自适应误差惩罚支撑向量回归机 AEPSVR 的实现步骤如下:

- (1)用常规的 ϵ -SVR 训练出初始的支撑向量回归机;
- (2)选择 erf 函数的参数 σ 和 σ 下降系数参数 $s(s > 1)$;
- (3)计算 $\sigma = \sigma/s$, 若更新后的 $\sigma \geq \text{sigmalb}$, 则转到第(4)步, 否则, 转到第(7)步;
- (4)计算 $\xi_i^{(*)}$, 并根据计算对应得 $C_i = C \cdot \text{erf}'(\xi_i^{(*)}, \sigma)$;
- (5)根据更新后的 C_i , 训练新的 ϵ -SVR;
- (6)返回第(3)步;
- (7)停止运算, 返回 w 和 b 的值。

3 实验结果及其分析

实验研究 sinc 函数和多元函数回归拟合问题。样本分别混入 3~8 个不同幅度的离群点, 它们是 $[5 \ 15] \cup [-15 \ -5]$ 区间的随机数。参数取为 $C=100$, $\sigma=100$, $s=5$, $\text{sigmalb}=0.1$, $\epsilon=0.005$ 。在训练结果的图示中, “*” 代表的是离群点, “.” 代表测试样本点, 实线为根据训练结果绘制的拟合曲线。

核函数对支撑向量回归的效果影响很大, 在拟合非线性数据时, rbf 核与 erbf 核的性能比线性核与多项式核性能更好。核参数 σ 相同时, erbf 核函数的回归受离群点的影响更明显。在实验中选择 erbf 核, 核函数形式如下:

$$K(x, x') = e^{-\frac{\|x-x'\|^2}{2s^2}} \tag{9}$$

加权鲁棒支撑向量回归方法(WRSVR)是张讲社等在文献[7]中提出的, 它与 WLS-SVM^[8]和 RSVR^[9]相比也具有较好的拟合性能。用 WRSVR 与 AEPSVR 做对比实验, WRSVR 参数按照文献[7]中的建议取为 $p=1.5$, $\eta=0.6$ 。

用 Err (样本集训练误差平方和)衡量测试的拟合误差, 计算方法如下:

$$\text{Err} = \sum_{i=1}^l (y_i - \bar{y}_i)^2 \tag{10}$$

3.1 sinc 函数拟合

拟合 sinc 函数 $y = \sin(x)/x$, x 初始点为 -5, 训练样本的间距为 0.2。训练样本数量均为 51 个。测试样本数量均为 50 个, 均匀的取在定义域上。实验结果如表 1 所示。

3.2 多元函数拟合

拟合 $y = 0.1x_1^3 + 0.12x_2^2 + 0.3x_3^2 + 0.4x_3x_4$, 其中 x_1, x_2, x_3 和 x_4 的初始点分别为 -5, -6, 1, -3, 样本间距分别为 0.2, 0.2, 0.1, 0.15, 训练样本数量均为 51 个。测试样本数量为 50 个, 均匀的取在定义域上。实验结果如表 2 所示。

3.3 离群点幅度对算法性能的影响

以拟合 sinc 函数为例, 测试离群点幅度对算法的影响。训练样本、测试样本和训练参数设置同 3.1 节。用离群点绝对值的均值(E)和标准差(Std)为指标衡量离群点的幅度, 其计算方法如下:

$$E = \frac{1}{l} \sum_{i=1}^l |y_i| \tag{11}$$

$$\text{Std} = \sqrt{\frac{\sum_{i=1}^l (|y_i| - E)^2}{l-1}} \tag{12}$$

实验表明, 离群点幅度从 $E=11$, $\text{Std}=2.0$ 到 $E=4.4$, $\text{Std}=0.8$ 时, AEPSVR 对幅度较大的离群点训练效果很稳定, 基本上不受离群点影响, 当离群点幅度降到 $E=4.4$, $\text{Std}=0.8$ 以下时, 训练误差和测试误差开始变大。导致这种结果的原因是训练参数 C 相对与离群点的幅度而言过大, 适当地减小 C 即可避免出现这种情况。例如, 在此例中, 取 $C=8$, 其他参数不变, 当 $E=1.1$, $\text{Std}=0.2$ 时, 训练误差和测试误差才开始变大, 当 $E=0.5$, $\text{Std}=0.1$ 时, 部分离群点已很难和正常样本区分开, 但 AEPSVR 仍能有较好的训练效果。

3.4 实验结果分析

AEPSVR 对每个训练样本分别设置正则化参数 C_i , 在训练中, 逐渐减小离群点对应的正则化参数, 由此减小离群点的影响。参数 C 具有两个作用: 其一, 调节正则化参数 C_i ; 其二, 参数 C 的取值和离群点的幅度相关, 如果离群点的幅度较大, C 可以取的比较大, 反之 C 要取小。参数 σ, s 和

表 1 sinc 函数拟合

	Err					
	3 离群点		6 离群点		8 离群点	
	训练	测试	训练	测试	训练	测试
ϵ -SVR	12.1289	6.1181	24.1308	12.1294	32.1716	16.1700
WRSVR	0.0036	0.0039	0.0048	0.0045	0.0121	0.0108
AEPSVR	0.0028	0.0033	0.0030	0.0035	0.0032	0.0037

表2 多元函数拟合

	Err					
	3 离群点		6 离群点		8 离群点	
	训练	测试	训练	测试	训练	测试
ϵ -SVR	772.4672	385.1052	799.9389	412.2536	835.2873	441.4451
WRSVR	6.1478	6.3419	10.6882	10.9776	18.3347	19.0509
AEPSVR	5.9537	5.4713	3.5335	3.8869	10.4421	9.8871

sigmalb 确定对离群点对应的正则化 C_i 约束效果。参数 s 调控 σ 的下降速度，一般取大于 1 的正数，较小的 σ 对应较小的 C_i ，即离群点对应的正则化参数逐步渐小。

实验表明，AEPSVR 算法的误差在 3 种方法中是最小的。 ϵ -SVR 算法对离群点非常敏感，随着离群点数量的增多，误差迅速增大。当离群点数量较少时，WRSVR 算法和 AEPSVR 算法的结果差不多，AEPSVR 性能稍好。如离群点距离正常样本较远时，WRSVR 和 AEPSVR 性能接近，都具有较好的抗离群点效果，WRSVR 的误差稍大。当离群点数量较多时，AEPSVR 算法性能明显好于 WRSVR 和 ϵ -SVR，达到了很高的拟合精度和泛化性能，而且随着离群点增加，AEPSVR 的误差只是缓慢增加，说明 AEPSVR 在离群点幅度较小或数量较多的情况下性能仍然稳定。在多元函数拟合实验中，离群点的幅度相对较小，AEPSVR 和 WRSVR 受离群点的影响比较大，因此误差比 sinc 函数拟合时要大一些，但精度仍然较好。

4 结束语

本文提出了一种自适应误差惩罚支撑向量回归机 (AEPSVR)，它改进支撑向量回归算法的鲁棒性，将离群点在训练中影响大幅度降低。由于该算法是以 ϵ -SVR 为基础，因此能将各种求解常规 SVR 的优化方法用于 AEPSVR 的求解。迭代方式的鲁棒支撑向量机的缺点是训练时间较长，进一步的研究工作将是提高它的泛化性能和求解速度。另外，研究一般代价函数形式及其对支撑向量回归算法的影响也很有必要。

参考文献

- [1] Smola A J and Schölkopf B. A tutorial on support vector regression. *Statistics and Computing*, 2004, 14(3): 199-222.
- [2] Schölkopf B, Smola A J and Williamson R C, et al. New support vector algorithm. *Neural Computation*, 2000, 12(12): 1207-1245.
- [3] Song Q, Hu W, and Xie W. Robust support vector machine with bullet hole image classification. *IEEE Trans. on Systems, Man and Cybernetics C*, 2002, 32(4): 440-448.
- [4] Weston J and Herbrich R. Adaptive margin support vector machines. *Neural Information Processing Systems (NIPS) Conference Workshop on Advance in Large Margin*

- [5] Xu Linli, Crammer K, and Schuurmans D. Robust support vector machine training via convex outlier ablation. In *Proceedings of the 21st National Conference on Artificial Intelligence(AAAI-06)*, Boston USA, 2006: 536-546.
- [6] Zhan Yiqiang and Shen Dinggang. An adaptive error penalization method for training an efficient and generalized SVM. *Pattern Recognition*, 2006, 39(3): 342-350.
- [7] 张讲社, 郭高. 加权稳健支撑向量回归方法. *计算机学报*, 2005, 28(7): 1171-1177.
Zhang Jiang-she and Guo Gao. Reweighted robust support vector regression method. *Chinese Journal of Computer*, 2005, 28(7): 1171-1177.
- [8] Suykens J A K, De Brahanter J, Lukas L, and Vandewalle J. Weighted least squares support vector machine: robustness and sparse approximation. *Neurocomputing*, 2002, 48(1-4): 85-105.
- [9] Chuang C C, Su F F, Jeng J T, and Hsiao C C. Robust support regression networks for function approximation with outliers. *IEEE Trans. on Neural Networks*, 2002, 13(6): 1322-1330.
- [10] Yong Zhan and HaoZhong Cheng. A robust support vector algorithm for harmonic and interharmonic analysis of electric power system. *Electric Power Systems Research*, 2005, 73(3): 393-400.
- [11] Wang Shitong, Zhu Jiagang and Chung Fu-Lai, et al. Experimental study on parameter choices in norm-r support vector regression machines with noisy input. *Soft Computing*, 2006, 10(3): 219-223.
- [12] Wang Shitong, Zhu Jiagang and Chung Fu-Lai, et al. Theoretically optimal parameter choices for support vector regression machines with noisy input. *Soft Computing*, 2005, 9(10): 732-741.

- 陈晓峰: 男, 1977 年生, 博士生, 从事人工智能、模式识别的研究。
王士同: 男, 1964 年生, 教授, 博士生导师, 从事人工智能、机器学习等研究。
曹苏群: 男, 1975 年生, 讲师, 博士生, 从事人工智能、软件工程等研究。