

文章编号: 1001-0920(2009)11-1657-06

两种求解非正定核 Laplace-SVR 的 SMO 算法

周晓剑, 马义中

(南京理工大学 管理科学与工程系, 南京 210094)

摘要: 提出 2 种用于求解非正定核 Laplace-SVR 的序列最小最优化(SMO)算法. 第 1 种算法仅针对 Laplace-SVR 而设计; 第 2 种算法将 Laplace-SVR 作为所要解决问题的一种特殊情况, 使算法更具通用性. 所提出的算法在保证收敛的前提下, 使非正定 Laplace-SVR 能够达到比较理想的回归精度, 具有一定的理论意义和实用价值.

关键词: 非正定核; 序列最小最优化算法; 支持向量回归机

中图分类号: TP18 **文献标识码:** A

Two types of SMO algorithms for solving Laplace-SVR with non-positive kernels

ZHOU Xiao-jian, MA Yi-zhong

(Department of Management Science and Technology, Nanjing University of Science and Technology, Nanjing 210094, China. Correspondent: ZHOU Xiao-jian, E-mail: xjzhou2008@yahoo.com.cn)

Abstract: Two types of sequential minimal optimization(SMO) algorithms applied in solving Laplace-SVR with non-positive kernels are proposed. The first algorithm is only designed for Laplace-SVR, and the second one regarding Laplace-SVR as a special case is done for a general purpose. Because of the difficulty of solving SVR with non-positive kernels, the presented algorithms have a certain theoretical and practical significance.

Key words: Non-positive kernel; SMO algorithm; SVR

1 引言

当采用支持向量机(SVM)解决实际分类或回归问题时,棘手之处在于如何提高计算效率. 针对这一问题,文献[1]提出了专用算法——选块算法. 但是,随着算法迭代次数的增多,计算速度变得十分缓慢. 针对选块算法存在的不足,文献[2]提出了适用于 SVC(Support vector classification)的“分解”算法,并由文献[3]将其扩展到支持向量回归机(SVR). “分解”算法有效地克服了选块算法的不足.

序列最小最优化(SMO)算法是分解算法中工作集的元素个数为 2 的一种特殊情形. 现有的 SMO 算法分为求解 SVC 的 SMO 算法和求解 SVR 的 SMO 算法. 求解 SVC 的 SMO 算法最早出现在文献[4]中,同年由 Smola 等^[5]将其扩展到求解 SVR. 以上这两类求解大型支持向量机的 SMO 算法都假定支持向量机的核函数是正定的且满足 Mercer 条件. 但是,在某些特定的应用领域,所使用的核函数

并不能保证为正定核函数,如神经网络中的 Sigmoid 核在某些条件下就是非正定的,这样现有的 SMO 算法的应用便受到了限制. 文献[6]提出的用于解决非正定核的 SVC 优化问题的方法,可以保持 SVC 的泛化性能. 然而有关非正定核 SVR 的求解方法,目前尚未见重要的研究成果公开发表. 本文将文献[6]的思想引入 Laplace-SVR 模型求解,以解决非正定核 Laplace-SVR 求解问题.

2 Laplace-SVR 的 SMO 算法的两种基本形式

2.1 Laplace-SVR 模型

给定数据集 $\{(x_1, y_1), \dots, (x_l, y_l)\}$ 及核矩阵 $K_{ij} = K(x_i, x_j)$, 若损失函数取 Laplace 函数

$$L(f(x) - y) = |f(x) - y|, \quad (1)$$

则构成 Laplace-SVR, 其模型如下:

$$\min \Phi(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l (\xi_i^- + \xi_i^+). \quad (2)$$

收稿日期: 2008-12-21; 修回日期: 2009-03-14.

基金项目: 国家自然科学基金项目(70672088); 国家自然科学基金国际交流项目(70711140386); 国家自然科学基金重点项目(70931002).

作者简介: 周晓剑(1979—),男,江西吉安人,博士生,从事人工神经网络、智能质量控制的研究; 马义中(1964—),男,河南泌阳人,教授,博士生导师,从事质量工程、质量管理等研究.

$$\begin{aligned} \text{s. t. } & f(\mathbf{x}_i) - y_i \leq \xi_i^+; \\ & y_i - f(\mathbf{x}_i) \leq \xi_i^-, i = 1, \dots, l; \\ & \xi_i^-, \xi_i^+ \geq 0. \end{aligned}$$

该模型的 Lagrange 对偶模型为

$$\begin{aligned} \min_{\alpha^*} & \frac{1}{2} \sum_{i,j=1}^l (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(\mathbf{x}_i, \mathbf{x}_j) - \\ & \sum_{i=1}^l (\alpha_i - \alpha_i^*)y_i. \quad (3) \\ \text{s. t. } & 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, \dots, l; \\ & \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0. \end{aligned}$$

下面对上述对偶问题采用两种方式进行处理:

第 1 种处理方式如下: 采取等量代换, 令 $\bar{\alpha} = \alpha_i - \alpha_i^*$, 则式(3)可写成

$$\begin{aligned} \min_{\bar{\alpha}} & \frac{1}{2} \sum_{i,j=1}^l \bar{\alpha}_i \bar{\alpha}_j K(\mathbf{x}_i, \mathbf{x}_j) - \sum_{i=1}^l \bar{\alpha}_i y_i. \quad (4) \\ \text{s. t. } & -C \leq \bar{\alpha}_i \leq C, i = 1, \dots, l; \\ & \sum_{i=1}^l \bar{\alpha}_i = 0. \end{aligned}$$

再将上述模型写成如下矩阵的形式:

$$\begin{aligned} \min_{\bar{\alpha}} & F(\bar{\alpha}) = \frac{1}{2} \bar{\alpha}^T \mathbf{K} \bar{\alpha} - \mathbf{y}^T \bar{\alpha}. \quad (5) \\ \text{s. t. } & -C \leq \bar{\alpha}_i \leq C, i = 1, \dots, l; \\ & \sum_{i=1}^l \bar{\alpha}_i = 0. \end{aligned}$$

第 2 种处理方式如下: 将式(3)展开, 则式(3)可写成如下矩阵的形式:

$$\begin{aligned} \min_{\bar{\alpha}} & F(\bar{\alpha}) = \frac{1}{2} \bar{\alpha}^T \mathbf{Q} \bar{\alpha} + \tilde{\mathbf{y}} \bar{\alpha}. \quad (6) \\ \text{s. t. } & 0 \leq \bar{\alpha}_i \leq C, t = 1, \dots, 2l; \\ & \mathbf{z} \bar{\alpha} = 0. \end{aligned}$$

其中

$$\begin{aligned} \tilde{\mathbf{y}} &= [-\mathbf{y}; \mathbf{y}]^T, \tilde{\alpha} = \begin{bmatrix} \alpha \\ \alpha^* \end{bmatrix}, \\ \mathbf{Q} &= \begin{bmatrix} \mathbf{K} & -\mathbf{K} \\ -\mathbf{K} & \mathbf{K} \end{bmatrix}, \mathbf{z} = [\mathbf{e} \quad -\mathbf{e}]. \quad (7) \end{aligned}$$

\mathbf{e} 是 $1 \times l$ 的单位向量.

下面基于式(5)和(6), 给出相应的两种 Laplace-SVR 的 SMO 模型.

2.2 第 1 种 Laplace-SVR 的 SMO 模型(简称模型 1)

通过简单推导, 易将式(5)写成如下模型:

$$\begin{aligned} \min_{\bar{\alpha}_i, \bar{\alpha}_j} & \frac{1}{2} [\bar{\alpha}_i \quad \bar{\alpha}_j] \begin{bmatrix} K_{ii} & K_{ij} \\ K_{ji} & K_{jj} \end{bmatrix} \begin{bmatrix} \bar{\alpha}_i \\ \bar{\alpha}_j \end{bmatrix} - \\ & \begin{bmatrix} \mathbf{y}_i \\ \mathbf{y}_j \end{bmatrix} + \mathbf{K}_{BN} \tilde{\alpha}_N \end{bmatrix}^T \begin{bmatrix} \bar{\alpha}_i \\ \bar{\alpha}_j \end{bmatrix}. \quad (8) \end{aligned}$$

$$\text{s. t. } -C \leq \bar{\alpha}_k \leq C, k \in \{i, j\};$$

$$\bar{\alpha}_i + \bar{\alpha}_j = -\sum_{k \neq i, j}^l \bar{\alpha}_k = \text{常数}.$$

2.3 第 2 种 Laplace-SVR 的 SMO 模型(简称模型 2)

同理, 可将式(6)写成如下模型:

$$\begin{aligned} \min_{\bar{\alpha}_i, \bar{\alpha}_j} & \frac{1}{2} [\bar{\alpha}_i \quad \bar{\alpha}_j] \begin{bmatrix} Q_{ii} & Q_{ij} \\ Q_{ji} & Q_{jj} \end{bmatrix} \begin{bmatrix} \bar{\alpha}_i \\ \bar{\alpha}_j \end{bmatrix} + \\ & \begin{bmatrix} \mathbf{y}_i \\ \mathbf{y}_j \end{bmatrix} + \mathbf{Q}_{BN} \tilde{\alpha}_N \end{bmatrix}^T \begin{bmatrix} \bar{\alpha}_i \\ \bar{\alpha}_j \end{bmatrix}. \quad (9) \\ \text{s. t. } & 0 \leq \bar{\alpha}_k \leq C, k \in \{i, j\}; \\ & \bar{\alpha}_i + \bar{\alpha}_j = -\sum_{k \neq i, j}^l \bar{\alpha}_k = \text{常数}. \end{aligned}$$

3 工作集的选取及停机准则的设定

工作集的选取是 SMO 算法中最为重要的环节之一, 工作集选取得好坏将直接影响算法的收敛速度. 对于模型 1, 可采取直接方式进行选取, 具体过程见 3.1 节. 但是, 对于模型 2, 则需要展开, 若不这样做, 而直接采用文献[7]的方法, 势必要同时考虑 4 个变量, 即 α_i, α_j 及 α_i^*, α_j^* , 从而不可避免地需要进行大量繁琐的判断, 以确定可行域在哪个象限. 本文对文献[7]中变量的判断方式进行改进, 只需选择 2 个变量即可.

停机准则从不同的角度一般可分为 3 种, 具体内容可参见文献[8], 本文则通过观察 KKT (Karush-Kuhn-Tucker) 条件的违背程度来判断是否可以停机. 下面分别给出模型 1 和模型 2 中工作集的选取步骤以及停机准则的推导过程.

3.1 模型 1 工作集的选取及停机准则

令

$$\omega(\bar{\alpha}) = \sum_i \bar{\alpha}_i K_i. \quad (10)$$

其中: $K_i = \phi(x_i)$, $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$. 引入 Lagrange 函数

$$\begin{aligned} \bar{L} &= \\ & \frac{1}{2} \omega(\bar{\alpha}) \cdot \omega(\bar{\alpha}) - \sum_{i=1}^l y_i \bar{\alpha}_i - \sum_{i=1}^l \delta_i (\bar{\alpha}_i + C) + \\ & \sum_{i=1}^l \mu_i (\bar{\alpha}_i - C) + \beta \sum_{i=1}^l \bar{\alpha}_i, \quad (11) \end{aligned}$$

则

$$\begin{aligned} \frac{\partial \bar{L}}{\partial \bar{\alpha}_i} &= \omega(\bar{\alpha}) K_i - y_i - \delta_i + \mu_i + \beta = 0, \\ & i = 1, \dots, l. \quad (12) \end{aligned}$$

对于式(12), 可分为以下 3 种互不相交的情形加以考虑:

- 1) $\bar{\alpha}_i = -C$, 则 $u_i = 0, \delta_i \geq 0, \omega(\bar{\alpha}) K_i - y_i + \beta \geq 0$,

即

$$\beta \geq -w(\bar{\alpha})K_i + y_i; \quad (13a)$$

2) $-C < \bar{\alpha}_i < C$, 则

$$u_i = 0, \delta_i = 0, w(\bar{\alpha})K_i - y_i + \beta = 0,$$

即

$$\beta = -w(\bar{\alpha})K_i + y_i; \quad (13b)$$

3) $\bar{\alpha}_i = C$, 则

$$u_i \geq 0, \delta_i = 0, w(\bar{\alpha})K_i - y_i + \beta \leq 0,$$

即

$$\beta \leq -w(\bar{\alpha})K_i + y_i. \quad (13c)$$

若定义

$$I_0 = \{i \mid -C < \bar{\alpha}_i < C\},$$

$$I_1 = \{i \mid \bar{\alpha}_i = -C\},$$

$$I_2 = \{i \mid \bar{\alpha}_i = C\},$$

并令

$$\bar{F}_i = -w(\bar{\alpha})K_i + y_i, \quad i \in I_1 \cup I_0, \quad (14)$$

$$\tilde{F}_i = -w(\bar{\alpha})K_i + y_i, \quad i \in I_2 \cup I_0. \quad (15)$$

则归纳上述 3 种情形, 可得

$$\begin{aligned} \beta &\leq \tilde{F}_i, \quad \forall i \in I_0 \cup I_2; \\ \beta &\geq \bar{F}_i, \quad \forall i \in I_0 \cup I_1. \end{aligned} \quad (16)$$

若再令

$$\begin{aligned} b_{\text{up}} &= \min\{\tilde{F}_i : i \in I_0 \cup I_2\}, \\ b_{\text{low}} &= \max\{\bar{F}_i : i \in I_0 \cup I_1\}, \end{aligned} \quad (17)$$

则可以得到工作集的选取方法及停机准则.

令

$$i = \arg \max_{i \in I_{\text{up}}(\bar{\alpha}, C)} \bar{F}_i, \quad j = \arg \min_{j \in I_{\text{low}}(\bar{\alpha}, C)} \bar{F}_j. \quad (18)$$

其中

$$\begin{aligned} I_{\text{up}}(\bar{\alpha}, C) &= \{i \mid i \in I_0 \cup I_1\}, \\ I_{\text{low}}(\bar{\alpha}, C) &= \{j \mid j \in I_0 \cup I_2\}. \end{aligned}$$

则工作集取为 $B = \{i, j\}$, 停机准则取为 $b_{\text{low}} \leq b_{\text{up}}$. 因为在数值解中不可能完全达到最优, 因此可用下式代替:

$$b_{\text{low}} \leq b_{\text{up}} + 2\text{tol},$$

其中 tol 表示误差所能容忍的范围.

3.2 模型 2 工作集的选取及停机准则

令

$$w(\tilde{\alpha}) = \sum_i \tilde{\alpha}_i Q_i. \quad (19)$$

其中

$$\begin{aligned} Q_i &= \phi(x_i), \quad Q(x_i, x_j) = \phi(x_i)^T \phi(x_j), \\ Q &= [K \quad -K; -K \quad K]. \end{aligned}$$

引入 Lagrange 函数

$$\begin{aligned} \bar{L} &= \frac{1}{2} w(\tilde{\alpha}) \cdot w(\tilde{\alpha}) + \sum_{i=1}^{2l} \tilde{y}_i \tilde{\alpha}_i - \sum_{i=1}^{2l} \delta_i \tilde{\alpha}_i + \\ &\quad \sum_{i=1}^{2l} \mu_i (\tilde{\alpha}_i - C) + \beta \sum_{i=1}^{2l} \tilde{\alpha}_i z_i, \end{aligned} \quad (20)$$

其中 z 在式(7)中已有定义. 则

$$\begin{aligned} \frac{\partial \bar{L}}{\partial \tilde{\alpha}_i} &= w(\tilde{\alpha})Q_i + \tilde{y}_i - \delta_i + \mu_i + \beta z_i = 0, \\ i &= 1, \dots, 2l. \end{aligned} \quad (21)$$

对于上式, 可分为以下 6 种互不相交的情形加以考虑:

1) $i \leq l, \tilde{\alpha}_i = 0$, 则

$$u_i = 0, \delta_i \geq 0, w(\tilde{\alpha})Q_i + \tilde{y}_i + \beta \geq 0,$$

即

$$\beta \geq -(w(\tilde{\alpha})Q_i + \tilde{y}_i); \quad (22a)$$

2) $i \leq l, 0 < \tilde{\alpha}_i < C$, 则

$$u_i = 0, \delta_i = 0, w(\tilde{\alpha})Q_i + \tilde{y}_i + \beta = 0,$$

即

$$\beta = -(w(\tilde{\alpha})Q_i + \tilde{y}_i); \quad (22b)$$

3) $i \leq l, \tilde{\alpha}_i = C$, 则

$$u_i \geq 0, \delta_i = 0, w(\tilde{\alpha})Q_i + \tilde{y}_i + \beta \leq 0,$$

即

$$\beta \leq -(w(\tilde{\alpha})Q_i + \tilde{y}_i); \quad (22c)$$

4) $l < i \leq 2l, \tilde{\alpha}_i = 0$, 则

$$u_i = 0, \delta_i \geq 0, w(\tilde{\alpha})Q_i + \tilde{y}_i - \beta \geq 0,$$

即

$$\beta \leq w(\tilde{\alpha})Q_i + \tilde{y}_i; \quad (22d)$$

5) $l < i \leq 2l, 0 < \tilde{\alpha}_i < C$, 则

$$u_i = 0, \delta_i = 0, w(\tilde{\alpha})Q_i + \tilde{y}_i - \beta = 0,$$

即

$$\beta = w(\tilde{\alpha})Q_i + \tilde{y}_i; \quad (22e)$$

6) $l < i \leq 2l, \tilde{\alpha}_i = C$, 则

$$u_i \geq 0, \delta_i = 0, w(\tilde{\alpha})Q_i + \tilde{y}_i - \beta \leq 0,$$

即

$$\beta \geq w(\tilde{\alpha})Q_i + \tilde{y}_i. \quad (22f)$$

若定义

$$\begin{aligned} I_{0a} &= \{i \mid i \leq l, 0 < \tilde{\alpha}_i < C\}, \\ I_{0b} &= \{i \mid l < i \leq 2l, 0 < \tilde{\alpha}_i < C\}, \\ I_1 &= \{i \mid i \leq l, \tilde{\alpha}_i = 0\}, \\ I_2 &= \{i \mid i \leq l, \tilde{\alpha}_i = C\}, \\ I_3 &= \{i \mid l < i \leq 2l, \tilde{\alpha}_i = 0\}, \\ I_4 &= \{i \mid l < i \leq 2l, \tilde{\alpha}_i = C\}, \end{aligned}$$

并定义 $I_0 = I_{0a} \cup I_{0b}$. 令

$$\bar{F}_i = \begin{cases} -(w(\tilde{\alpha})Q_i + \tilde{y}_i), & i \in I_1 \cup I_{0a}; \\ w(\tilde{\alpha})Q_i + \tilde{y}_i, & i \in I_4 \cup I_{0b}; \end{cases} \quad (23)$$

$$\tilde{F}_i = \begin{cases} -(w(\tilde{\alpha})Q_i + \tilde{y}_i), & i \in I_2 \cup I_{0a}; \\ w(\tilde{\alpha})Q_i + \tilde{y}_i, & i \in I_3 \cup I_{0b}. \end{cases} \quad (24)$$

则归纳上述 6 种情形可得

$$\begin{aligned} \beta &\leq \tilde{F}_i, \quad \forall i \in I_0 \cup I_2 \cup I_3; \\ \beta &\geq \bar{F}_i, \quad \forall i \in I_0 \cup I_1 \cup I_4. \end{aligned} \quad (25)$$

若再令

$$b_{up} = \min\{\bar{F}_i : i \in I_0 \cup I_2 \cup I_3\},$$

$$b_{low} = \max\{\bar{F}_i : i \in I_0 \cup I_1 \cup I_4\}, \quad (26)$$

则同理可以得到工作集的选取方法及停机准则. 令

$$i = \operatorname{argmax}_{i \in I_{up}(\bar{\alpha}, C)} \bar{F}_i, j = \operatorname{argmax}_{j \in I_{low}(\bar{\alpha}, C)} \bar{F}_j. \quad (27)$$

其中

$$I_{up}(\bar{\alpha}, C) = \{i \mid i \in I_0 \cup I_1 \cup I_4\},$$

$$I_{low}(\bar{\alpha}, C) = \{j \mid j \in I_0 \cup I_2 \cup I_3\}.$$

则工作集取 $B = \{i, j\}$, 停机准则为 $b_{low} \leq b_{up} + 2\text{tol}$.

从上述分析可以看出, 模型 1 与模型 2 的求解过程是殊途同归. 模型 1 通过等量代换对问题进行了有效的简化, 但这种简化只针对 Laplace-SVR 这一特殊情形, 求解过程并不具有通用性, 即可移植性不强. 模型 2 的求解思想更具有普遍意义, 因为当损失函数不像 Laplace 函数那么简单时, 同样可以采用本文提出的求解思路. 这里并不想将简单问题复杂化, 只是试图提出一种更具普遍意义的解决办法. 为此, 下面主要针对模型 2 进行讨论, 模型 1 可类似加以处理.

4 求解非正定核 Laplace-SVR 的 SMO 算法

当核函数为非正定时, 式(6)中的核矩阵 Q 中的分块矩阵 K 不能写成如下内积的形式:

$$K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j), \quad (28)$$

所以得不到式(2)的那种形式. 因此, 从式(6)中解出 $\tilde{\alpha}$ 后, 不能确定它就是式(2)的解. 换言之, 式(2)与(6)的对偶关系不再成立, 从而无法得到有效的回归函数. 对此, 考虑如下新的二次规划问题:

$$\min \Phi(w, \xi) = \frac{1}{2} \alpha^T Q \alpha + C \sum_{i=1}^l (\xi_i^- + \xi_i^+). \quad (29)$$

s. t. $(Q^* \alpha)_i - y_i \leq \xi_i^+;$
 $y_i - (Q^* \alpha)_i \leq \xi_i^-, i = 1, \dots, l;$
 $\xi_i^-, \xi_i^+ \geq 0.$

其中: $Q = [Q^* \quad -Q^*], Q^* = [K \quad -K]$.

上式是将式(19)代入(2)得到的. 注意到式(29)中的 α 可能是负的. 这样做的目的是为了研究用式(6)求出 $\tilde{\alpha}$ 后, 用 $\tilde{\alpha}$ 来构建回归函数的误差是否会很大. 为此, 有如下定理:

定理 1 如果 $\hat{\alpha}$ 是式(6)的稳定点, 则它是式(29)的可行点.

证明 假设 $\hat{\alpha}$ 是式(6)的稳定点, 则它满足 KKT 条件, 即存在 Lagrange 乘子向量 δ, μ, β 满足

$$Q\hat{\alpha} - \tilde{y} - \delta + \mu - \beta = 0,$$

$$\delta \geq 0, \mu \geq 0, \delta\hat{\alpha} = 0,$$

$$\mu(\hat{\alpha} - C) = 0, \quad (30)$$

其中 $\beta = \beta[e \quad -e]^T$.

由 $\mu \geq 0$ 得 $Q\hat{\alpha} - \tilde{y} \leq \delta + \beta$. 当 $i < l$ 时, 有

$$(Q\hat{\alpha} - \tilde{y})_i = (Q^* \hat{\alpha})_i - y_i;$$

当 $l \leq i \leq 2l$ 时, 有

$$(Q\hat{\alpha} - \tilde{y})_i = -(Q^* \hat{\alpha})_{i-l} + y_{i-l}.$$

因此, 综合以上两种情况, 可写成

$$(Q\hat{\alpha} - \tilde{y}) = [(Q^* \hat{\alpha}) - y; -(Q^* \hat{\alpha}) + y].$$

所以 $[\alpha; \xi_i^+; \xi_i^-] = [\hat{\alpha}; \delta + \beta]$ 即为式(29)的可行解. \square

从定理 1 可以看出, 如果式(6)的稳定点 $\hat{\alpha}$ 不存在太多的非零元素, 即使 Q 是非正定的, 训练误差也不会太大. 基于以上分析, 本文提出用于求解非正定核 Laplace-SVR 的 SMO 算法. 为便于问题的求解及收敛性的判定, 作如下变换:

在式(9)中, 令

$$\tilde{\alpha}_i = \tilde{\alpha}_i^k + d_i, \tilde{\alpha}_j = \tilde{\alpha}_j^k + d_j, \quad (31)$$

则含两变量的子最优化问题可化为

$$\min_{d_i, d_j} \frac{1}{2} [d_i \quad d_j] \begin{bmatrix} Q_{ii} & Q_{ij} \\ Q_{ji} & Q_{jj} \end{bmatrix} \begin{bmatrix} d_i \\ d_j \end{bmatrix} +$$

$$[\nabla F(\tilde{\alpha}_i^k) \quad \nabla F(\tilde{\alpha}_j^k)] \begin{bmatrix} d_i \\ d_j \end{bmatrix}. \quad (32)$$

$$\text{s. t. } 0 \leq \tilde{\alpha}_i^k + d_i; \tilde{\alpha}_j^k + d_j \leq C;$$

$$m_i d_i + m_j d_j = 0;$$

$$m_k = \begin{cases} 1, & 0 \leq k \leq l; \\ -1, & l \leq k \leq 2l; \\ k \in \{i, j\}. \end{cases}$$

对于式(32), 可分为以下 2 种情形加以讨论:

第 1 种情形: $i \leq l, j \leq l$ 或 $l < i \leq 2l, l < j \leq 2l$. 由 $(\tilde{\alpha}_i^k + d_i) + (\tilde{\alpha}_j^k + d_j) = \tilde{\alpha}_i^k + \tilde{\alpha}_j^k$ 得 $d_i = -d_j$, 并令

$$L = \max(-\tilde{\alpha}_j^k, \tilde{\alpha}_i^k - C),$$

$$H = \min(\tilde{\alpha}_i^k, C - \tilde{\alpha}_j^k), \quad (33)$$

则式(32)可化为

$$\min_{d_j} \frac{1}{2} [Q_{ii} - 2Q_{ij} + Q_{jj}] d_j^2 +$$

$$(-\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k)) d_j, \quad (34)$$

s. t. $L \leq d_j \leq H$.

第 2 种情形: $i \leq l, l < j \leq 2l$ 或 $l < i \leq 2l, j \leq l$. 由 $(\tilde{\alpha}_i^k + d_i) - (\tilde{\alpha}_j^k + d_j) = \tilde{\alpha}_i^k - \tilde{\alpha}_j^k$ 得 $d_i = d_j$. 同理, 令

$$L = \max(-\tilde{\alpha}_i^k, -\tilde{\alpha}_j^k),$$

$$H = \min(C - \tilde{\alpha}_i^k, C - \tilde{\alpha}_j^k), \quad (35)$$

则式(32)可化为

$$\min_{d_j} \frac{1}{2} (Q_{ii} + 2Q_{ij} + Q_{jj}) d_j^2 +$$

$$(\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k))d_j, \quad (36) \quad \text{有}$$

$$\text{s. t. } L \leq d_j \leq H.$$

这样便将优化问题转化为在给定区间求抛物线的极值点问题,从而可以解析求解式(2).

下面给出 Laplace-SVR 的 SMO 算法.

输入:样本集 $\{(x_1, y_1), \dots, (x_l, y_l)\}$, 惩罚系数 $C > 0$, 核函数 K , 精度 $\text{tol} > 0$ 及 $\tilde{\alpha}$;

输出:已优化的 $\hat{\alpha}$.

Step1: 设定精度 tol , $\tilde{\alpha}^0 = \mathbf{0}$, 令 $k = 0$, 并初始化 b_{low} 和 b_{up} .

Step2: while($b_{\text{low}} > b_{\text{up}} + 2\text{tol}$).

Step2.1: 按式(27)中的准则选取工作集 $B = \{i, j\}$;

Step2.2: 如果是第 1 种情形,则求解式(34). 若 $Q_{ij} - 2Q_{ij} + Q_{jj} > 0$, 则

$$\hat{d}_j = \max\left(-\frac{(\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k))d_j}{Q_{ii} - 2Q_{ij} + Q_{jj}}, L\right);$$

否则,如果 $i \leq l, j \leq l$, 则

$$\hat{d}_j = L; \quad (37)$$

否则,即如果 $l < i \leq 2l, l < j \leq 2l$, 则

$$\hat{d}_j = H; \quad (38)$$

计算

$$\hat{d}_i = -\hat{d}_j;$$

否则,求解式(36). 若 $Q_{ii} + 2Q_{ij} + Q_{jj} > 0$, 则

$$\hat{d}_j = \min\left\{\max\left(-\frac{\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k)}{Q_{ii} + 2Q_{ij} + Q_{jj}}, L\right), H\right\};$$

否则,若 $\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k) > 0$, 则

$$\hat{d}_j = L; \quad (39)$$

否则,若 $\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k) < 0$, 则

$$\hat{d}_j = H; \quad (40)$$

否则

$$\hat{d}_j = \arg \min_{j \in \{L, H\}} \{f(L), f(H)\}, \quad (41)$$

计算

$$\hat{d}_i = \hat{d}_j.$$

Step2.3: 计算

$$\tilde{\alpha}_i^{k+1} = \tilde{\alpha}_i^k + \hat{d}_i, \tilde{\alpha}_j^{k+1} = \tilde{\alpha}_j^k + \hat{d}_j.$$

Step2.4: 令 $k = k + 1$, 并计算 b_{low} 和 b_{up} .

endwhile.

Step3: 取近似最优解 $\hat{\alpha} = \tilde{\alpha}^{k+1}$, 算法结束.

从以上算法可以看出,当 $Q_{ii} - 2Q_{ij} + Q_{jj} \geq 0$ 或 $Q_{ii} + 2Q_{ij} + Q_{jj} \geq 0$ 时,式(34)和(36)的目标函数为凸的抛物线或直线.有关正定核情况下的 SMO 算法的收敛性证明可以参见文献[9],这里将着重讨论 $Q_{ii} - 2Q_{ij} + Q_{jj} < 0$ 或 $Q_{ii} + 2Q_{ij} + Q_{jj} < 0$ 时的情形,并给出收敛性证明.

定理 2 存在 $\xi > 0$,使得对于任意的自然数 k ,

$$F(\tilde{\alpha}^{k+1}) - F(\tilde{\alpha}^k) \leq -\frac{\xi}{2} \|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2. \quad (42)$$

证明 分 2 种情形加以证明.

1) 当 $i \leq l, j \leq l$ 或 $l < i \leq 2l, l < j \leq 2l$ 时,结合式(23), (24)和(27)易得 $(-\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k))\hat{d}_j \leq 0$. 并且从 $\hat{d}_i = -\hat{d}_j$ 可得 $\|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2 = 2\hat{d}_j^2$. 因此,由式(34)的目标函数可得

$$\begin{aligned} F(\tilde{\alpha}^{k+1}) - F(\tilde{\alpha}^k) &\leq \\ &\frac{1}{2}(Q_{ii} - 2Q_{ij} + Q_{jj})\hat{d}_j^2 = \\ &\frac{1}{4}(Q_{ii} - 2Q_{ij} + Q_{jj})\|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2 \leq \\ &-\frac{\xi}{2}\|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2, \end{aligned} \quad (43)$$

其中

$$\xi = -\max_{i,j} \left\{ \frac{Q_{ii} - 2Q_{ij} + Q_{jj}}{2} \mid Q_{ii} - 2Q_{ij} + Q_{jj} < 0 \right\}.$$

2) 当 $i \leq l, l < j \leq 2l$ 或 $l < i \leq 2l, j \leq l$ 时,从工作集的选择策略无法判定 $\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k)$ 的符号,但通过步长选取策略(见式(39)和(40))可得 $(\nabla F(\tilde{\alpha}_i^k) + \nabla F(\tilde{\alpha}_j^k))\hat{d}_j \leq 0$. 并结合 $\hat{d}_i = \hat{d}_j$ (此时 $\|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2 = 2\hat{d}_j^2$),类似于式(43)可得

$$\begin{aligned} F(\tilde{\alpha}^{k+1}) - F(\tilde{\alpha}^k) &\leq \\ &\frac{1}{2}(Q_{ii} + 2Q_{ij} + Q_{jj})\hat{d}_j^2 \leq \\ &-\frac{\xi}{2}\|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\|^2, \end{aligned}$$

其中

$$\xi = -\max_{i,j} \left\{ \frac{Q_{ii} + 2Q_{ij} + Q_{jj}}{2} \mid Q_{ii} + 2Q_{ij} + Q_{jj} < 0 \right\}. \quad \square$$

从以上定理可以看出,可以考虑用式(37)~(40)及(41)作为步长取值策略的理由.这样做的目的是要得到 $\lim_{k \rightarrow \infty} \|\tilde{\alpha}^{k+1} - \tilde{\alpha}^k\| = 0$,因而也就保证了算法的收敛性.

虽然这里提出的求解非正定核的 SMO 算法是收敛到稳定点而不是全局最优,但当稳定点上的支持向量并不多时,或者说稳定点的非零元素并不多时,用非正定核训练时误差并不大.以下的实验说明了这一点.

5 实验及其结果

5.1 实验设计

取函数 $y = \sin(\exp(x)) (x \in [-4, 2])$ 为基准信号,令间隔为 0.1 产生训练样本.其中:非正定核取组合高斯核

$$\exp\left(-\frac{\|s-t\|^2}{\sigma_1}\right) + \exp\left(-\frac{\|s-t\|^2}{\sigma_2}\right) - \exp\left(-\frac{\|s-t\|^2}{\sigma_3}\right)^{[10]}$$

标准差分别取为 $\sigma_1 = 0.8, \sigma_2 = 1.2, \sigma_3 = 4$; 正定核取 Gauss 径向基核函数 $\exp(-\|s-t\|^2/2\sigma^2)$, 其中 $\sigma = 1$.

5.2 实验结果与分析

本实验中参数 C 取为 $C = 10$, 有关参数的选择方法可参见文献[11,12]; 预设精度为 $\text{tol} = 0.05$. 回归的结果如图 1 和图 2 所示. 图中: 符号“*”为样本点, 实线为回归线. 同时, 从以下 3 个方面对实验的回归结果进行定量比较(结果见表 1):




图 1 用非正定核对 $y = \sin(\exp(x))$ 回归的结果




图 2 用正定核对 $y = \sin(\exp(x))$ 回归的结果

1) 最大绝对误差

$$\text{MAE}(\text{Max absolute error}) = \max |y_i - \hat{y}|, i = 1, \dots, n,$$

其中 n 为样本容量;

2) 平均绝对误差

$$\text{AAE}(\text{Average absolute error}) = \sum_{i=1}^{n_{\text{error}}} |y_i - \hat{y}| / n_{\text{error}};$$

表 1 用正定核和非正定核回归的误差比较

误差	用正定核回归	用非正定核回归
MAE	0.6170	0.1478
AAE	0.0784	0.0151
RMSE	0.1588	0.0334

3) 均方根误差

$$\text{RMSE}(\text{Root mean square error}) = \sqrt{\sum_{i=1}^{n_{\text{error}}} (y_i - \hat{y})^2 / n_{\text{error}}}.$$

从图 1, 图 2 及表 1 的误差比较分析可以看出, 对于如 $\sin(\exp(x))$ 之类的比较难以回归的函数, 采用非正定核进行回归比采用正定核能够达到更理想的回归精度. 这说明在某些情况下采用非正定核的必要性以及本文算法的有效性.

6 结 论

本文提出了 2 种用于求解非正定核 Laplace-SVR 的思路. 对于模型 1 并没有过多论述, 因为模型 1 可视为模型 2 的一种特殊情形. 本文主要针对更为普遍的情形加以阐述, 并设计了相应的 SMO 算法, 这样做的目的是使求解的思路更具通用性. 对于非正定核, 如 Sigmoid 核函数(包括本文所使用的核函数), 因为只能保证解是局部最优的, 而不一定是全局最优, 因此如何克服它们的不足并发挥它们的优势, 仍然是一个有意义的研究课题.

参考文献(References)

[1] Vapnik V N. Estimation of dependences based on empirical data [M]. Berlin: Springer-Verlag, 1982.

[2] Osuna E, Freund R, Girosi F. Improved training algorithm for support vector machines [C]. Neural Networks and Signal Processing. Amelia Island, FL, 1997: 276-285.

[3] Osuna E. Support vector machines: Training and applications [M]. Cambridge, MA: Massachusetts Institute of Technology, 1998.

[4] Platt J C. Fast training of support vector machines using sequential minimal optimization — Advances in kernel methods: Support vector machines [M]. Cambridge MA: MIT Press, 1998: 185-208.

[5] Smola A J, Schölkopf B. A tutorial on support vector regression [R]. London: Royal Holloway College, University of London, 1998.

[6] Lin H-T, Lin C-J. A study on sigmoid kernels for SVM and the training of non-psd kernels by SMO-type methods[R]. Taipei: Department of Computer Science and Information Engineering, National Taiwan University, 2003.

[7] Keerthi S, Shevade S, Bhattacharyya C, et al. Improvements to SMO algorithm for SVM regression [J]. IEEE Trans on Neural Networks, 2000, 11(5): 1188-1193.