

## 支持向量机回归与分类解的关系

## The Relation of Solution Between Support Vector Machine Regression and Classification

周德强

ZHOU De-qiang

(长江大学信息与数学学院,湖北荆州 434023)

(School of Information and Mathematics, Yangtze University, Jingzhou, Hubei, 434023, China)

摘要: 将线性  $L_p (p=1)$  和  $L_\infty$  损失函数下的支持向量机回归与分类解的关系及支持向量机回归与  $\xi$ -支持向量机分类解的关系, 推广到非线性  $L_p (p \geq 1)$  和  $L_\infty$  损失函数上, 得到这些解关系更一般的形式。

关键词: 支持向量机 回归 分类 损失函数

中图分类号: O177.91, TP18 文献标识码: A 文章编号: 1005-9164(2008)03-0282-03

**Abstract** The relation of solution between SVMR and SVMC, and the relation of solution between SVMR and  $\nu$ -SVMC based on the linear  $L_p$  and  $L_\infty$  loss function to the non-linear  $L_p$  and  $L_\infty$  loss function are generalized, and the general form of original theory is obtained.

**Key words** support vector machine, regression, classification, loss function

支持向量机 (SVM) 由 Vapnik. V<sup>[1]</sup> 在 1995 年提出来, 是近年来机器学习研究的一项重大成果. SVM 方法最初用于模式识别 (分类) 问题, 进而成功地推广到函数回归与逼近问题. 随之, 支持向量机回归与分类的关系也得到广泛研究. Pontil 等人在  $L_p$  损失函数  $p=1$  的情况下研究支持向量机回归 (SVMR) 与分类 (SVMC) 解的关系<sup>[2]</sup>. 本文将线性  $L_p (p=1)$  和  $L_\infty$  损失函数下的支持向量机回归与分类解的关系及支持向量机回归与  $\xi$ -支持向量机分类解的关系, 推广到非线性  $L_p (p \geq 1)$  和  $L_\infty$  损失函数上, 得到这些解关系更一般的形式.

## 1 预备知识

在支持向量机分类 (SVMC)<sup>[1,3]</sup> 问题中, 给定  $l$  个样本  $(x_1, y_1), \dots, (x_l, y_l)$ , 其中  $x_i \in \mathbb{R}^d, y_i \in \{-1, +1\}$ , 目标是寻找一个超平面  $(k, b)$ , 使它能以最大间隔将给定的正样本和负样本分开. 为了形式化表述这一目标, 引入非负变量  $Y_i \geq 0, i=1, 2, \dots, l$ , 根据这些变量, SVMC 问题可描述为:

$$\min_{k, b, Y} \frac{1}{2} \|k\|^2 + CF \sum_{i=1}^l Y_i, \quad (1)$$

约束条件是

$$y_i (k \cdot x_i + b) \geq 1 - Y_i; Y_i \geq 0, i=1, 2, \dots, l,$$

其中  $F(u)$  是一个单调的凸泛函 ( $p \geq 1$ ), 称为损失函数,  $C \geq 0$  为惩罚因子<sup>[1,2]</sup>. 在本文所讨论的问题中, 考虑  $L_p$  损失函数<sup>[2,3]</sup>, 则此时的 SVMC 问题等价于问题 (1) 中取凸泛函  $F(Y) = \sum_{i=1}^l Y_i$ , 那么上述 SVMC 问题变为:

$$\min_{k, b, Y} \frac{1}{2} \|k\|^2 + C \sum_{i=1}^l Y_i, \quad (2)$$

约束条件是

$$y_i (k \cdot x_i + b) \geq 1 - Y_i; Y_i \geq 0, i=1, 2, \dots, l.$$

在支持向量机回归 (SVMR)<sup>[1,3]</sup> 问题中, 目标是构造一个超平面使之尽可能接近大多数样本点. 给定  $l$  个样本  $(x_1, y_1), \dots, (x_l, y_l)$ , 从这些有限样本中, 需要找到回归函数的一个有效估计. 这可表述为:

$$\min_{k, b, Y, \Psi} \frac{1}{2} \|k\|^2 + C \sum_{i=1}^l (Y_i + (\Psi_i)^p), \quad (3)$$

约束条件是

$$y_i - (k \cdot x_i + b) \leq X_+ Y_i - \Psi_i; -y_i + (k \cdot x_i + b) \leq X_+ Y_i; Y_i, \Psi_i \geq 0, i=1, 2, \dots, l,$$

其中

收稿日期: 2007-08-31

作者简介: 周德强 (1975-), 男, 硕士, 讲师, 主要从事机器学习理论研究.

$$Lx = |y - (k \cdot x + b)|^p =$$

$$\begin{cases} 0, & \text{当 } |y - (k \cdot x + b)| \leq X \\ (|y - (k \cdot x + b)| - X)^p, & \text{其它,} \end{cases}$$

是 Vapnik 的  $X$ -不敏感损失函数<sup>[1,3]</sup>. 对所有  $i$ , 若  $y_i \in \{-1, 1\}$ , 可以在相同的样本集上研究 SVMR 与 SVMC 之间的关系.

**定理 1**<sup>[2]</sup> 假定分类问题 (2) 由正则化参数  $C$  求解, 最优解为  $(k, b)$ , 那么, 存在一个数  $a \in (0, 1)$ , 使得  $\forall X \in [a, 1)$ , 若回归问题 (3) 由正则化参数  $(1 - X)C$  求解, 则最优解为  $(1 - X)(k, b)$ .

## 2 SVMR 与 SVMC 解的关系

通常情况下, SVMC 与 SVMR 在求解的过程中使用一个非线性核  $K(x_i, y_i)$ <sup>[2,4]</sup>. 为了表述简单, 选择超平面的一个线性表达形式, 所得的结论可应用到非线性情况.

注意, 当在  $y_i \in \{-1, 1\}$  上讨论 SVMR 问题时, 若  $X \geq 1, k = 0$ , 则  $Y = 0, \check{Y} = 0$  是对于问题 (3) 的一个最优解. 因此, 限制在  $X < 1$  的条件下讨论 SVMR 与 SVMC 的关系, 得到定理 1 的推广形式.

**定理 2** 假定分类问题 (2) 由正则化参数  $C$  求解, 最优解为  $(k, b)$ , 那么, 存在一个数  $a \in (0, 1)$ , 使得  $\forall X \in [a, 1)$ . 若回归问题 (3) 由正则化参数  $(1 - X)^2 \cdot pC$  ( $p \geq 1$ ) 求解, 则最优解为  $(1 - X)(k, b)$ .

证明 作变量替换:

$$Z_i = \begin{cases} Y_i, & \text{当 } y_i = 1, \\ \check{Y}_i, & \text{当 } y_i = -1, \end{cases} \quad Z_i = \begin{cases} \check{Y}_i, & \text{当 } y_i = 1, \\ Y_i, & \text{当 } y_i = -1. \end{cases}$$

结合替换以及  $y_i \in \{-1, 1\}$  产生问题 (3) 的修正:

$$\min_{k, b, Z, \check{Z}} \frac{1}{2} \|k\|^2 + \frac{C}{p} \left( \sum_{i=1}^l (Z_i + (\check{Z}_i)^p) \right), \quad (4)$$

约束条件是

$$y_i(k \cdot x_i + b) \geq 1 - X - Z_i; y_i(k \cdot x_i + b) \leq$$

$$1 + X + \check{Z}_i; Z_i, \check{Z}_i \geq 0, i = 1, 2, \dots, l.$$

进一步, 在每一个约束条件两边同除以  $1 - X$  并作变量替换:

$$k' = \frac{k}{1 - X}, b' = \frac{b}{1 - X}, e = \frac{Z}{1 - X}, e^* = \frac{\check{Z}}{1 - X}$$

得到

$$\min_{k', b', e, e^*} \frac{1}{2} \|k'\|^2 + \frac{C(1 - X)^{p-2}}{p} \left( \sum_{i=1}^l (e^i + (e^*)^p) \right). \quad (5)$$

约束条件是

$$y_i(k' \cdot x_i + b') \geq 1 - e; y_i(k' \cdot x_i + b') \leq \frac{1 + X}{1 - X}$$

$$+ e^*; e, e^* \geq 0, i = 1, 2, \dots, l.$$

观察 (5) 式, 可假设  $X > 1$ , 约束条件的第 2 个集合将自动满足  $e^* = 0$ , 在此假定下构造拉格朗日对偶

可以得到:

$$\begin{aligned} & \min_{U, V} \frac{1}{2} \sum_{i=1}^l (U_i - \check{U}_i) D_{ij} (U_i - \check{U}_i) + \\ & \sum_{i=1}^l (U_i + V_i) \left( \frac{U_i + V_i}{C(1 - X)^{p-2}} \right)^{\frac{1}{p-1}} - \sum_{i=1}^l U_i - \\ & \frac{C(1 - X)^{p-2}}{p} \sum_{i=1}^l \left( \frac{U_i + V_i}{C(1 - X)^{p-2}} \right)^{\frac{p}{p-1}} + \frac{1 + X}{1 - X} \sum_{i=1}^l \check{U}_i, \end{aligned} \quad (6)$$

约束条件是

$$\sum_{i=1}^l U_i y_i = \sum_{i=1}^l \check{U}_i y_i; V_i \geq 0, U_i, \check{U}_i \geq 0, U_i, \check{U}_i \leq$$

$$C(1 - X)^{p-2}, i = 1, 2, \dots, l,$$

其中  $D$  是对称半正定矩阵, 其元素  $D_{ij} = y_i y_j x_i x_j$ . 对所有的  $X$  充分接近 1 时,  $e^*$  将全为零. 事实上, 当  $e = 0, e^* = 0$  时, 它们是 (6) 式中损失函数为零时的可行解, 如果  $e^*$  是正的, 对  $X$  充分接近 1 时, (6) 式的解  $U_i, \check{U}_i$  也都是正的. 因此, 假定  $X$  充分接近 1, 可以从 (5) 式中排除  $e^*$ , 从 (6) 式中排除  $\check{U}_i$ , 移走这些项后, 得到一个与问题 (2) 的对偶问题本质上一致的优化问题:

$$\begin{aligned} & \min_{U, V} \frac{1}{2} \sum_{i=1}^l U_i D_{ij} U_i + \sum_{i=1}^l (U_i + \\ & V_i) \left( \frac{U_i + V_i}{C(1 - X)^{p-2}} \right)^{\frac{1}{p-1}} - \sum_{i=1}^l U_i - \\ & \frac{C(1 - X)^{p-2}}{p} \sum_{i=1}^l \left( \frac{U_i + V_i}{C(1 - X)^{p-2}} \right)^{\frac{p}{p-1}}, \end{aligned} \quad (7)$$

约束条件是

$$\sum_{i=1}^l U_i y_i = 0; V_i \geq 0, U_i \geq 0; U_i \leq C(1 - X)^{p-2}, i =$$

$$1, 2, \dots, l.$$

通过这一对偶形式, 可恢复稍有修正的 SVMC 问题:

$$\min_{k, b, Y} \frac{1}{2} \|k\|^2 + C(1 - X)^{(p-2)} \left( \sum_{i=1}^l Y_i \right), \quad (8)$$

约束条件是

$$y_i(k \cdot x_i + b) \geq 1 - Y_i; Y_i \geq 0, i = 1, 2, \dots, l.$$

因而定理得证.

注 (I) 定理 2 是对定理 1 在非线形损失函数  $L_p$  上的直接推广, 它包含了  $p = 1$  的线性情况.

(II) 对于  $p = 2$  的情况, 在从 (4) 式到 (5) 式的过程中,  $(1 - X)$  这一因子自动消除, 因此 (5) 式中的目标函数简化为  $\frac{1}{2} \|k'\|^2 + \frac{C}{p} \sum_{i=1}^l (e^2 + (e^*)^2)$ . 定理变为对充分大的  $X$  如果求解问题 (2) 用正则化参数  $C$  得到解  $(k, b)$ , 那么, 同样用正则化参数  $C$  求解问题 (3) 得到解  $(1 - X)(k, b)$ .

(III) 因  $L_1$  与  $L_2$  及相应的  $L_X$  损失函数具有独特之处 (使优化问题较为简单), 通常在实际中应用广

泛. 但由定理 2 可知, 对于基于更广范围的  $L_p$  与  $L_\infty$  型的凸损失函数, 也能将 SVMC 问题视为 SVMR 问题的一种特殊情况.

### 3 SVMR 与 $\nu$ -SVMC 解的关系

$g$ -SVMC 是 SVMC 的推广, 所谓  $g$ -SVMC, 必须最小化问题:

$$\min_{k, b, d, \gamma_i} \frac{1}{2} \|k\|^2 - g d + \frac{C}{p} \sum_{i=1}^l \Psi, \quad (9)$$

约束条件是

$$y_i(k \cdot x_i + b) \geq d - \gamma_i; \gamma_i \geq 0, i = 1, 2, \dots, l.$$

特别地, 在  $g$ -SVMC 问题中当参数  $g = 0$  时,  $d$  可取值  $d = 1^{[4]}$ , 此时  $g$ -SVMC 问题就是 SVMC 问题. 当取  $p = 1$ , 并考虑线性可分情况时, 有

定理 3<sup>[5]</sup> 设带有正则化参数  $C$  且  $d \geq 1$  的  $g$ -SVMC 问题 (9) 的解为  $(w, b, d)$ , 于是存在一个常数  $a$ , 当  $a \in (0, 1)$ , 使对任意的  $X \in (a, 1)$ , 存在带有正则化参数为  $(1 - X)C$  的 SVMR 问题 (3) 的解为  $(1 - X)(k, b)$ .

对更一般的非线性损失函数  $L_p$  与  $L_\infty (p > 1)$ , 有

定理 4 设带有正则化参数  $C$  且  $d \geq 1$  的  $g$ -SVMC 问题 (9) 的解为  $(w, b, d)$ , 于是存在一个常数  $a$ , 当  $a \in (0, 1)$ , 使对任意的  $X \in (a, 1)$ , 存在带有正则化参数为  $(1 - X)^{2-p}C$  的 SVMR 问题 (3) 的解为  $(1 - X)(k, b)$ .

可采用类似定理 3 的证明方法证明定理 4, 这里只给出要证明问题 (3) 所对应的修正后的  $g$ -SVMC 问题:

$$\min_{k, b, \gamma_i} \frac{1}{2} \|k\|^2 - g d + \frac{C}{p} (1 - X)^{2-p} \sum_{i=1}^l \Psi, \quad (10)$$

约束条件是

$$y_i(k \cdot x_i + b) \geq 1 + d - \gamma_i; \gamma_i \geq 0, d \geq 1, i = 1,$$

$2, \dots, l$ .

在  $g$ -SVMC 问题中, 当  $g = 0, d = 1$  时,  $g$ -SVMC 问题就是 SVMC 问题, 由此可得到

推论 1 设带有正则化参数  $C$  且 SVMC 问题 (2) 的解为  $(w, b)$ , 于是存在一个常数  $a$ , 当  $a \in (0, 1)$ , 使对任意的  $X \in (a, 1)$ , 存在带有正则化参数为  $(1 - X)^{2-p}C$  的 SVMR 问题 (3) 的解为  $(1 - X)(k, b)$ .

推论 1 恰好是定理 2 中所反映出的 SVMR 与 SVMC 解之间的关系, 而当  $p = 1$  时即为定理 1.

由上述定理可见, 在 SVM 技术中, 凸损失函数的不同选择, 定义了不同结构的学习问题. 但不论损失函数是线性还是非线性形式, 对一个给定的 SVMC 问题, 总存在某一个具有特定参数的 SVMR 问题, 使得两者的解等价.

参考文献:

- [1] Vapnik V. The nature of statistical learning theory [M]. Heidelberg, Germany: Springer Verlag, 1995.
- [2] Pontil M. Ryan Rifkin and Theodoros Evgeniou, from regression to classification in support vector machines. Proceedings—European Symposium on artificial new works [C]. Bruges (Belgium): D-Facto Public, 1999 21–23.
- [3] Vapnik V. Statistical learning theory [M]. New York: John Wiley, 1998.
- [4] Burges C J C. A tutorial on support vector machines for pattern recognition [J]. Kata Mining and Knowledge Discovery, 1998, 2(2): 121–167.
- [5] 邹斌, 李落清. 支持向量机回归与  $\nu$  支持向量机分类解的关系 [J]. 湖北大学学报: 自然科学版, 2004, 26(1): 12–15.

(责任编辑: 尹 闯)

### 科学家发现调控恐惧记忆的关键因素

5-羟色胺是神经系统内一个非常重要的神经递质, 广泛参与各种行为和生理过程. 一般认为, 5-羟色胺功能低下可以导致多种精神类疾病, 尤其是焦虑、抑郁和创伤后应激综合征等, 而这些疾病都伴有学习和记忆的障碍. 中国科学院的科学家们利用条件性基因敲除等遗传学手段, 得到中枢神经系统中的 5-羟色胺神经元缺乏的小鼠, 比较分析 5-羟色胺敲除小鼠与正常小鼠在焦虑和恐惧行为学测试中的表现. 这种敲除手段不影响神经系统其他神经元包括表达 5-羟色胺受体的神经元的产生. 研究结果发现, 5-羟色胺敲除小鼠焦虑水平低于对照小鼠, 在特定环境给予足部电刺激的恐惧记忆测试中, 5-羟色胺敲除小鼠的恐惧记忆不仅增强而且长时间保持, 而正常小鼠的恐惧记忆在短期内消退. 科学家们再进行脑内直接给予 5-羟色胺至小鼠 5-羟色胺敲除小鼠后的分析测试, 发现这种增强的恐惧记忆能够像对照小鼠一样消退, 这进一步说明增强的恐惧记忆是由 5-羟色胺缺乏引起的. 这个研究结果将有助于建立对人类创伤后应激综合征的治疗策略.

(据科学时报)