

模糊多类 SVM 模型

李昆仑^{1,2}, 黄厚宽¹, 田盛丰¹

(11 北京交通大学计算机与信息技术学院, 北京 100044; 21 河北大学计算机学院, 河北保定 071002)

摘 要: 利用 SVM 处理多类分类问题, 是当前的研究热点之一. 本文提出了一种模糊多类支持向量机模型, 即 FMSVM. 该方法是在 Weston 等人提出的多类 SVM 模型中引入模糊成员函数, 针对每个输入数据对分类结果的不同影响, 该模糊成员函数得到相应的值, 由此得到不同的惩罚值. 从而在构造分类超平面时, 可以忽略那些对分类结果影响很小的数据. 理论分析与数值实验都表明, 该算法具有良好的鲁棒性.

关键词: 多类分类; 支持向量机 (SVM); 模糊成员函数

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2004) 05-0832-03

Fuzzy Support Vector Machine for Multi-Class Classification

LI Kunlun^{1,2}, HUANG Houkuan¹, TIAN Shengfeng¹

(11 School of Computer & Information Technology, Beijing Jiaotong University, Beijing 100044, China;
21 School of Computer Science, Hebei University, Baoding, Hebei 071002, China)

Abstract: How to process multi-class problem with SVM is one of the present research focuses. We propose a fuzzy multi-class SVM model referred as FMSVM. It is constructed by introducing a fuzzy membership function to the penalty in the quadratic problem of Weston and Watkins, the membership function acquire different values for each input data according to their different affects on the classification results. Hence, we can ignore the data, which affect the classification result a little. Therefore different input points can make different contributions to the learning of the decision surface, i. e., the optimal separating hyperplane. Both theoretical analysis and digital experiment results show that the model proposed here works very well on benchmark data sets and also has the property of robustness.

Key words: multi-class classification; support vector machine (SVM); fuzzy membership function

1 引言

支持向量机(Support vector machine, SVM)是统计机器学习理论(Statistical learning theory, SLT)的核心内容,它基于 VC 维理论和结构风险最小化原理^[1,2]. 在很大程度上克服了传统机器学习中维数灾难、局部极小点以及过学习等难以克服的困难. 它具有良好的泛化能力, 并拥有传统的机器学习方法无法比拟的性能. 这一理论已经成功应用于数据挖掘和模式识别, 例如手写体数字的识别、物体的识别、语音识别等.

SVM 的研究中有两类问题亟待解决. 其一, 是如何将两类问题的解决办法有效地推广至多类问题. 目前, 已经有一些卓有成效的方法, 如 1221、122r 以及 DAGSVM 等方法. 上述的方法都是基于解决多个两类分类问题的. 换言之, SVM 的多类分类器一般是从二类分类出发设计的. 其二, SVM 对孤立点和噪音数据是非常敏感的, 如何克服这一困难.

与传统的多类 SVM 不同, FMSVM 首先在 Weston 和 Watkins 所提出的多类 SVM 分类器直接构造方法^[5]的惩罚项中引入模糊成员函数. 在处理训练数据时, 根据它们在训练过

程中重要程度的不同, 区别对待. 也就是说, 将目标函数中的惩罚项模糊化, 重构优化问题及其约束条件, 然后重构其 Lagrangian 公式, 使得原公式(模型)所对应的最优分类超平面的解即为其对偶形式的解.

2 多类 SVM 分类方法简介

下面简单介绍几种常见的多类 SVM 分类算法.

2.1 1 / on2 versus 2rest0 (一对多, 122r) 方法^[2]

对于 k- (k > 2) 类分类问题, 构造 k 个 2 类 SVM 分类器, 每一类对应其中的一个. 在构造第 i 个 2 类分类器时, 把属于第 i 类的样本点标记为正, 不属于这一类的样本点标记为负. 也就是说, 第 i 个 2 类 SVM 分类器所构造的分类超平面 (separating hyperplane), 把第 i 类与其它 (i-1) 类分割开. 测试时, 对测试样本分别计算各个 2 类分类器的决策函数值, 选择最大的函数值所对应的类别为测试数据的类别.

2.2 1 / on2 versus 2one0 (一对一, 1221) 方法^[6]

对于 k 类分类问题, 任意两个不同的类构造一个 2 类 SVM 分类器. 这时共需要构造 $N = k(k-1)/2$ 个 2 类 SVM

分类器. 在构造第 i 类和第 j 类的 2 类 SVM 分类器时, 分别选取属于第 i 类和第 j 类的样本数据作为训练样本, 将属于第 i 类的样本标记为正, 将属于第 j 类的样本标记为负. 测试时, 将数据对所有的 2 类分类器分别进行测试, 并累计各类的得分, 选择得分最高的类为测试数据的类别.

2.1.3 构造 k 类 SVM 分类器的直接方法

Weston 和 Watkins 提出了解决 k - 类问题的一种直接方法^[5], 实际上它是标准 SVM 中二次优化问题的一种自然的推广:

$$\min_{(w, N)} \langle (w, N) \rangle = \frac{1}{2} \sum_{m=1}^k (w_m \# w_m) + C \prod_{i=1}^l \sum_{m=1}^k E_{mX_i} N^m \quad (1)$$

其约束条件为:

$$(w_y \# x_i) + b_y E (w_m \# x_i) + b_m + 2 - N^m, \quad (2)$$

$$N^m E 0, \quad m = 1, \dots, l, \quad y_i \in \{1, \dots, k\}, \quad m \times y_i$$

由此, 得到下面的 k 类 SVM 分类器的决策函数:

$$f(x) = \arg \max_k [(w_i \# x) + b_i], \quad i = 1, \dots, k \quad (3)$$

本文将对上述 SVM 多类分类方法进行改进, 在惩罚项中引入模糊成员函数. 其目的在于根据每个数据点对分类结果的不同影响, 模糊成员函数为其赋予不同的值. 因而, 可以降低噪音对分类结果的影响.

3 引入模糊成员函数的多类 SVM)) FMSVM

3.1 输入数据的模糊性

在传统的 SVM 理论中, 训练过程对于那些远离它们所属类的训练点是十分敏感的. 如何设置惩罚项中自由参数 C 的值是非常重要的. 较大的 C 意味着为错误项指定了较大的惩罚值, 可以减少错误分类点. 另一方面, 较小的 C 的值, 意味着忽略了一些微不足道0 的误分类点, 因而可得到较大的分类间隔(margin). 无论 C 的值是大还是小, 在 SVM 的训练过程中这个参数的值始终是固定的. 也就是说, 在 SVM 的训练过程中, 所有的训练点都是被平等对待的. 这样就导致了 SVM 对某些特殊情形的过分敏感, 例如孤立点与噪声. 这种情形即是所谓的 过学习0 (overfitting) 现象.

在很多实际应用问题中, 不同的训练点对分类结果的影响是不同的. 一般来说, 训练集中存在某些点对分类结果的影响很大, 同时也存在一些点对分类结果的影响很小甚至是微不足道的. 因此在处理分类问题时, 必须将那些/ 重要的点0 正确分类, 并且可以忽略那些/ 微不足道0 的点, 比如说带有/ 噪声0 的点和距离类中心很远的孤立点.

3.1.2 引入模糊成员函数的多类 SVM 分类器

假设给出了一个带有类别标号和模糊成员函数的训练集 $S: (x_1, y_1, s_1), \dots, (x_l, y_l, s_l)$, 每一个训练样本 $x_i \in R^N$ 都给出了与其对应的类别标号 $y_i \in \{1, 2, \dots, k\}$, 以及模糊成员函数 s_i , $RF s_i \in [0, 1]$, 其中 $i = 1, \dots, l$, R 是一个充分小的正数. 令 $z = U(x)$ 表示特征空间中的向量, 而 U 是由输入空间 R^N 到特征空间 Z 的映射.

最优分类超平面可由下面二次优化问题的解给出:

$$\min \frac{1}{2} \sum_{m=1}^k (w_m \# w_m) + C \prod_{i=1}^l \sum_{m=1}^k E_{mX_i} s_i^m N^m \quad (4)$$

$$s. t. \quad (w_y \# x_i) + b_y E (w_m \# x_i) + b_m + 2 - N^m,$$

$$N^m E 0, \quad i = 1, \dots, l, \quad m, \quad y_i \in \{1, \dots, k\}, \quad m \times k \quad (5)$$

其中 C 是惩罚常数, N 是松弛变量, s 是所引入的模糊成员函数. 对应的 Lagrangian 公式为:

$$\begin{aligned} L(w, b, N, A, B) = & \frac{1}{2} \sum_{m=1}^k (w_m \# w_m) + C \prod_{i=1}^l \sum_{m=1}^k s_i^m N^m \\ & - \sum_{i=1}^l \sum_{m=1}^k A_i^m [(w_{y_i} - w_m) \# x_i] \\ & + b_{y_i} - b_m - 2 + N^m] - \prod_{i=1}^l \sum_{m=1}^k B_i^m N^m \end{aligned} \quad (6)$$

其中, A, B 均为 Lagrange 因子, 它们满足下面的条件:

$$A_i^m = 0, \quad B_i^m = 0, \quad N_i^m = 2, \quad s_i^m = 1, \quad i = 1, \dots, l$$

以及约束条件:

$$A_i^m E 0, \quad B_i^m E 0, \quad N_i^m E 0, \quad RF s_i^m \in [0, 1]$$

分别求关于 w_n, b_n 的偏导数, 则在鞍点处应满足:

$$\frac{\partial L}{\partial w_n} = 0, \quad w_n = \sum_{i=1}^l (A_i c_i^n - A_i^n) x_i \quad (7)$$

$$\frac{\partial L}{\partial b_n} = 0, \quad \sum_{i=1}^l A_i c_i^n = \sum_{i=1}^l A_i^n \quad (8)$$

$$\frac{\partial L}{\partial N_i^m} = 0, \quad C s_i^m = A_i^m + B_i^m \quad \text{和} \quad 0 \leq F A_i^m \leq C s_i^m \quad (9)$$

其中, 引入了符号 c_i^n 和 A_i , 其意义如下:

$$c_i^n = \begin{cases} 1, & \text{当 } y_i = n \text{ 时} \\ 0, & \text{当 } y_i \neq n \text{ 时} \end{cases}, \quad A_i = \sum_{m=1}^k A_i^m \quad (10)$$

将上述结果代入式 (6), 可以得到下面的:

$$\begin{aligned} W = & \frac{1}{2} \sum_{m=1}^k \sum_{i=1}^l \sum_{j=1}^l E (c_i^m A_j - A_i^m) (c_j^m A_j - A_j^m) (x_i \# x_j) \\ & - \sum_{m=1}^k \sum_{i=1}^l \sum_{j=1}^l E A_i^m [\sum_{j=1}^l (c_j^m A_j - A_j^m) (x_i \# x_j) \\ & - \sum_{j=1}^l (c_j^m A_j - A_j^m) (x_i \# x_j) + b_{y_i} + b_m - 2] \\ & - \sum_{m=1}^k \sum_{i=1}^l \sum_{j=1}^l E A_i^m N^m + C \prod_{m=1}^k \sum_{i=1}^l s_i^m N^m - \prod_{m=1}^k \sum_{i=1}^l B_i^m N^m \end{aligned} \quad (11)$$

将其进一步化简为:

$$\min W = 2 \sum_{i,m} A_i^m - \frac{1}{2} \sum_{i,j,m} [c_j^m A_j - 2 A_i^m A_j + A_i^m A_j^m] (x_i \# x_j) \quad (12)$$

约束条件为:

$$\sum_{i=1}^l A_i^m = \sum_{i=1}^l c_i^m A_i, \quad n = 1, \dots, k;$$

$$0 \leq A_i^m \leq C s_i^m; \quad A_i^m = 0; \quad i = 1, \dots, l; \quad m, \quad y_i \in \{1, \dots, k\} \quad (13)$$

因而, 可以得到下面的决策函数:

$$f(x, A) = \arg \max_n [\sum_{i=1}^l (c_i^n A_i - A_i^n) (x \# x) + b_n] \quad (14)$$

若给定了一个模糊训练集, 根据上述方法构造的模糊多类 SVM, 即 FMSVM 仍采用分类间隔的最大化以及分类错误的最小化, 使得分类器具有较好的泛化能力. 与传统 SVM 所不同的是, 在 FMSVM 中将惩罚项模糊化, 以降低不太重要的数据对分类结果的影响.

4 数值实验

首先在 UCI 机器学习数据库^[7] 中选择了 7 个数据集,

分别是 iris, wine, glass, soy 和 vowel, 以及 Blood2cell 和 Thyroid. 为了验证 FMSVM 对噪音数据的可行性, 利用 NDC 数据生成器^[8]生成了一个数据集 FTAIN. 其中, 含有 1000 个样本点, 每个样本数据的维数为 8, 样本集类别数为 3, 该样本集服从正态分布, 在此基础上加入了 50 个噪音数据(均值为 0, 谱密度为一个正常数的白噪声). 在实验中, 取 $s_i = y_i/k$, 其中 k 为类别数, y_i 为类别标号($y_i = 1, \dots, k$).

为了使得实验更具有说服力, 对每一个算法都选取了不同的 C 值, 并使用了两个核函数: 多项式函数 $K(x, x_i) = [(x \# x_i) + 1]^d$ 与径向基函数 $K(x, y) = \exp(-R|x - y|^2)$. 每个算法在实现过程中, 核函数的参数, 比如多项式核函数中的次数 d , 以及径向基函数中的跨度系数 R 的取值使用了几个值进行比较. 采用 10 重交叉验证法估计分类器的正确性, 表 1 和表 2 中给出了平均正确率以及标准偏差.

对实验结果的分析可以看出, FMSVM 算法在所选定的数据集上的性能是较好的. 在/ glass0, / soy0 和/ vow2e0 上的分类结果优于其他算法; 但在/ iris0 和/ wine0 上, 分类结果比 $\mathcal{L}2\mathcal{L}1$ 差. 在/ blood cell0 上, 分类正确率高于其它算法; 但在/ thyroid0 上, 分类正确率低于 $\mathcal{L}2\mathcal{L}1$ 算法, 高于其它算法. 在表 1 和表 2 中, Data 指数据集, Kernel 指核函数, Pam 指参数, &C 表示文[5]中所提出的多类 SVM 算法.

把所 FMSVM 算法与 $\mathcal{L}2\mathcal{L}r$, $\mathcal{L}2\mathcal{L}1$ 以及 Weston 等人提出多类 SVM 算法进行了比较. 由实验结果可以看出, FMSVM 与其它几种分类器相比, 对由数据生成器所生成的带有噪声的 FTAIN 来说, 分类精度大大提高了. 由此可见该算法对处理噪音数据是非常有效的. 并且, 在对实验结论进行的统计显著性分析来看, 该算法的分类正确率明显高于其他三种算法.

5 结论

在本文中, 提出了一种 FMSVM 模型, 即模糊多类 SVM 模型. 它是在 Weston 等人所提出的算法的基础上, 引入一个模糊成员函数. 对每一个数据, 模糊成员函数都给出一个值以确定该数据属于某一类的隶属度, 从而可以确定该点对分类结果的影响程度. 由此可见, 依据此模型得到的算法可以减少噪音数据或孤立点对分类结果的影响, 增强算法的鲁棒性. 理论分析与实验结果表明, 我们所提出的模型是可行的和有效的.

参考文献:

- [1] J C Burges. A tutorial on support vector machines for pattern recognition[J]. Data Mining and Knowledge Discovery, 1998, 2: 121- 167.
- [2] V Vapnik. Statistical Learning Theory[M]. Wiley-Interscience, Publication, 1998.
- [3] C W Hsu, C J Lin. A comparison of methods for multiclass support vector machines[J]. IEEE Trans on Neural Networks, 2002, 13(2): 415- 425.
- [4] Li Kunlun, Huang Houkuan, Tian Shengfeng. A novel multiclass SVM classifier based on DDAG[A]. Proc. of IEEE ICMLC. 02[C]. China: IEEE, 2002. 1203- 1207.

表 1 在第一组数据上的实验结论

Data	Kernel	Pam	$\mathcal{L}2\mathcal{L}r$ (%)	$\mathcal{L}2\mathcal{L}1$ (%)	&C(%)	FMSVM(%)
iris	Poly	4	96.00? 0.127	96.29? 0.125	96.24? 0.130	96.34? 0.125
		5	96.89? 0.130	96.94? 0.125	96.86? 0.135	96.86? 0.127
		6	96.87? 0.187	96.89? 0.175	96.32? 0.163	96.33? 0.133
RBF	0.11	97.02? 0.152	97.02? 0.169	97.02? 0.145	97.08? 0.125	
	1	96.81? 0.1130	96.89? 0.112	96.56? 0.110	96.65? 0.110	
wine	Poly	3	97.46? 0.156	97.56? 0.145	97.34? 0.155	97.78? 0.150
		4	97.57? 0.1155	97.53? 0.140	97.57? 0.136	97.65? 0.136
RBF	3	97.76? 0.127	97.77? 0.127	97.76? 0.127	97.68? 0.138	
	0.12	97.56? 0.167	97.64? 0.165	97.70? 0.155	97.68? 0.152	
glass	Poly	3	82.12? 0.1107	82.25? 0.1102	81.25? 0.185	83.30? 0.182
		5	82.12? 0.176	82.45? 0.172	82.33? 0.170	83.30? 0.187
RBF	0.13	81.56? 0.166	83.35? 0.157	82.46? 0.132	85.50? 0.167	
	1	82.56? 0.128	83.75? 0.130	82.56? 0.198	84.50? 0.1102	
soy	Poly	0.15	96.66? 0.1103	97.35? 0.192	97.56? 0.187	97.00? 0.156
		2	97.66? 0.165	97.35? 0.152	97.26? 0.177	97.50? 0.166
RBF	4	95.66? 0.156	96.35? 0.166	97.22? 0.158	97.50? 0.151	
	5	95.68? 0.145	96.33? 0.153	97.22? 0.168	97.40? 0.185	
vowel	Poly	0.12	96.66? 0.136	97.35? 0.155	97.46? 0.162	97.50? 0.187
		2	96.66? 0.153	97.35? 0.166	97.46? 0.137	97.50? 0.125
RBF	5	96.65? 0.186	97.33? 0.192	97.45? 0.176	97.55? 0.195	
	6	96.65? 0.156	97.36? 0.168	97.45? 0.146	97.55? 0.1102	

表 2 在第二组数据 blood2cell 和 thyroid 上的实验结果

Blood cell	Poly	4	90.25? 0.1105	92.10? 0.1114	90.35? 0.1120	91.33? 0.1118
		5	91.03? 0.1134	91.90? 0.1125	90.20? 0.1152	92.10? 0.1131
		6	91.25? 0.1198	91.58? 0.1105	91.24? 0.1187	92.12? 0.1168
RBF	10	91.52? 0.164	91.58? 0.138	91.24? 0.158	92.12? 0.166	
	Thyroid	Poly	4	92.27? 0.2115	96.56? 0.167	96.62? 0.137
RBF		10	92.30? 0.1182	95.75? 0.146	95.16? 0.1103	95.46? 0.1124
FTAIN	RBF	8	75.03? 0.3125	76.36? 0.287	73.23? 0.3126	80.25? 0.1157
		10	76.30? 0.3174	76.35? 0.267	75.00? 0.3133	81.02? 0.1123

[5] J Weston, C Watkins. Multiclass Support Vector Machines [R]. Technical Report, CSD-TR-29804, Department of Computer Science, Royal Holloway University of London, England, May 1998.

[6] Ulrich Kressel. Pairwise classification and support vector machines [A]. In B Schölkopf, C J C Burges, A J Smola, editors, Advances in Kernel Method Support Vector Learning [C]. Cambridge, MA, MIT Press, 1998. 255- 268.

[7] <http://www.ics.uci.edu/~mlearn/MLRepository.html>[DB/OL].

[8] <http://www.cs.wisc.edu/musicant/data/ndc>[DB/OL]. 1998.

作者简介:



李昆仑 男, 1962 年出生于河北保定, 现为北京交大计算机与信息技术学院博士生, 主要研究方向为机器学习、数据挖掘.

黄厚宽 男, 1940 年出生于四川遂宁, 现为北京交大计算机与信息技术学院教授, 博导, 主要研究方向为机器学习、数据挖掘、智能网络安全和多 Agent 等.