

# 基于推广能力测度的多类 SVDD 模式识别方法

朱孝开, 杨德贵

(国防科学技术大学电子科学与工程学院空间电子信息技术研究所, 湖南长沙 410073)

**摘要:** 经典的基于距离测度的SVDD(Support Vector Domain Description)方法在解决两类(多类)识别问题时具有误判率较高、识别率低于普通二类SVC分类器等缺点. 本文在分析其原因的基础上, 提出了一种更能反映样本与类别本质关系的推广能力测度, 并由此提出了具有多层结构的多类SVDD模式识别方法. 对实测雷达一维距离像数据的测试表明, 该方法在保留了经典SVDD识别器算法复杂程度低、扩充性强、对训练样本数据规模上要求低等优点的同时, 有效地降低了误判率, 识别率已接近甚至达到二类SVC的水平.

**关键词:** 模式识别; SVDD; 多层结构; 多分类算法

中图分类号: TP391.4 文献标识码: A 文章编号: 0372-2112(2009)03-0464-06

## Multi-Class Support Vector Domain Description for Pattern Recognition Based on a Measure of Expansibility

ZHU Xiao-kai, YANG De-gui

(Research Institute of Space Electronics Information Technology, College of Electric Science and Engineering, NUDT, Changsha, Hunan 410073, China)

**Abstract:** Classic SVDD classifiers, which use distance measures, have lower recognition rate than normal two class SVM classifiers. After analyzing the causes, a new measure is proposed, which can represent the more essential relationship between samples and categories. And then, a multi level SVDD is proposed. The experiment on real one dimensional range profiles data shows that, the multi level SVDD reserves the lower complexity, higher expansibility and fewer requirements to sample size, ERs are reduced effectively, CR is increased even to the level of two class SVM classifiers.

**Key words:** pattern recognition; SVDD; multi level architecture; multi class classification

### 1 引言

1999年, David M. J. Tax在SVM理论<sup>[1]</sup>的基础上提出了一种数据描述算法——支撑向量域描述(Support Vector Domain Description, SVDD)<sup>[2]</sup>, 其主要思想是通过计算包含一组数据的最小超球形边界来对该组数据进行描述. SVDD与文[3]提出的高维空间复杂几何形体覆盖神经网络一样, 可以应用于模式识别领域. 目前, 已被应用于人脸检测<sup>[4]</sup>、车牌识别<sup>[5]</sup>等多类识别问题之中. 相比于由二类SVM推广得到的多类分类器, 基于距离测度的经典SVDD分类器具有算法复杂性低、扩充性强、对训练样本数据规模上要求不高等优点, 但是也存在误判率较高的缺点. 鉴于此, 本文提出了一种更能反映样本与类别本质关系的推广能力测度, 并在此基础上, 提出一种具有多层结构的SVDD模式识别方法, 可以在保留了经典SVDD方法优点的同时, 有效降低误判率, 提高识别性能.

### 2 支撑向量域描述 SVDD

#### 2.1 SVDD基本理论

这里采用的是Scholkopf对SVDD的描述<sup>[6]</sup>, 当使用RBF核函数时, 与Tax提出的可以互相转换<sup>[2]</sup>.

设 $x_1, x_2, \dots, x_l$ 是某一集合 $X$ 中的样本点,  $X$ 是 $R^N$ 的紧子集.  $\Phi: X \rightarrow H$ 为核函数对应的映射, 将训练样本映射到特征空间中. 为了把样本点与坐标原点分开, 需解决如下二次优化问题:

$$\begin{aligned} \min_{w \in H, \xi \in R^l, b \in R^1} & \frac{1}{2} \|w\|^2 + \frac{1}{vl} \sum_i \xi_i - b \\ \text{s. t. } & (w \cdot \Phi(x_i)) \geq b - \xi_i, \xi_i \geq 0 \end{aligned} \quad (1)$$

其中,  $w$ 表示分界面,  $b$ 为判决阈值,  $\xi_i$ 为松弛变量,  $v \in (0, 1)$ 为一常数, 用来控制支撑向量在训练样本中所占的比例,  $l$ 为样本个数.

决策函数为:

$$f(x) = \text{sgn}(w \cdot \Phi(x) - b) \quad (2)$$

$w$  和  $b$  为式(1)中二次优化问题的解. 引入拉格朗日乘子  $\alpha_i, \beta_i \geq 0$ , 原优化问题等价于

$$\min L(w, \xi, b, \alpha, \beta) = \frac{1}{2} \|w\|^2 + \frac{1}{vl} \sum_i \xi_i - b - \sum_i \alpha_i ((w \cdot x_i) - b + \xi_i) - \sum_i \beta_i \xi_i \quad (3)$$

分别令  $w, \xi, b$  的偏导为零, 可以得到

$$w = \sum_i \alpha_i \Phi(x_i) \quad (4)$$

$$\alpha_i = \frac{1}{vl} - \beta_i \leq \frac{1}{vl}, \sum_i \alpha_i = 1 \quad (5)$$

将式(4)、(5)代入式(3), 得到

$$\min \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j) \quad (6)$$

$$s. t. 0 \leq \alpha_i \leq \frac{1}{vl}, \sum_i \alpha_i = 1$$

其中,  $k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ . 解此二次优化问题, 可以得到  $\alpha_i$ . 参考式(4),  $w$  只与  $\alpha_i > 0$  的项有关, 所以  $\alpha_i > 0$  所对应的  $x_i$  被称为支撑向量. 其中  $0 < \alpha_i < \frac{1}{vl}$

所对应的  $x_i$  又被称为 UBSV, 而  $\alpha_i = \frac{1}{vl}$  所对应的  $x_i$  被称为 BSV, 后文将详细介绍这两类支撑向量.

将式(4)代入式(2), 判决函数最终可写为

$$f(x) = \text{sgn}(\sum_i \alpha_i k(x_i, x) - b) \quad (7)$$

式中,  $b$  的值可由下式给出

$$b = \sum_i \alpha_i k(x_i, x_j) \quad (8)$$

$x_j$  为任一 UBSV.

算法最终得到一超球分界面, 此分界面与式(1)中的参数  $v$  以及核函数的选择有关, 下面两节将对此分别阐述.

### 2.2 参数 $v$ 对分界面的影响

以一组月牙形分布的二维数据为训练样本(样本大小为 100), 以径向基函数(RBF)为核函数, 固定 RBF 核的参数  $\sigma$  为常数 10 可以得到如图 1 所示的 SVDD 描述. 图 1 中, ‘x’ 表示训练样本, 加圈点为 BSV, 实心点为 UBSV.

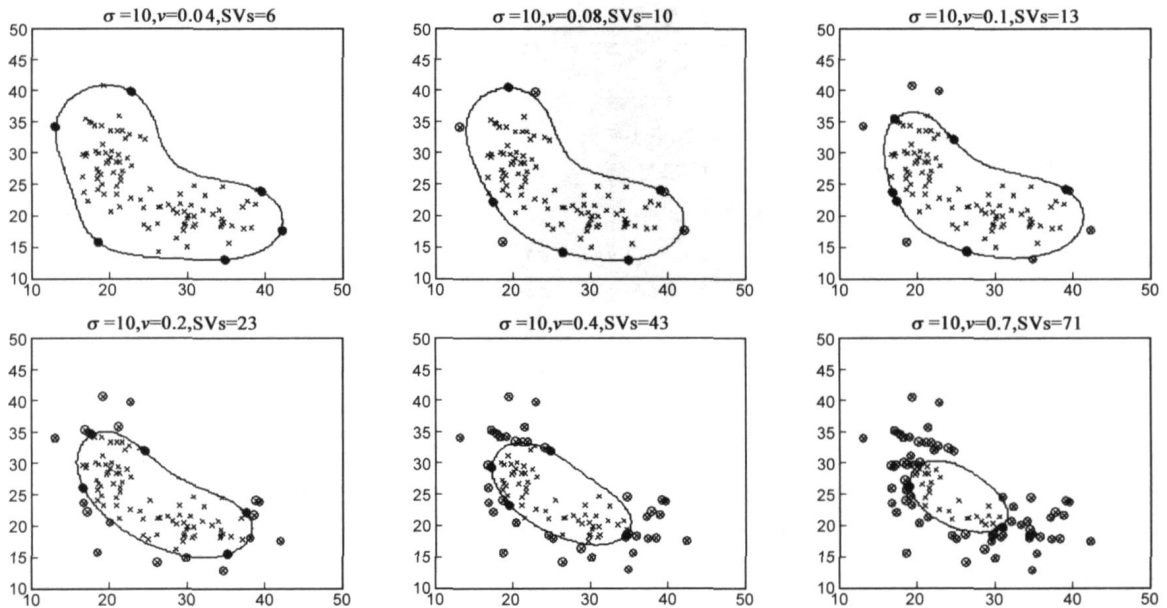


图1 参数  $v$  取不同值时得到的 SVDD 描述

由式(6),  $\alpha_i$  的上限为  $\frac{1}{vl}$ , 支撑向量总数的下限为  $vl$ , 其中,  $l$  为样本总数, 于是  $v$  即代表样本中支撑向量的最小比例. 事实上, 当 UBSV 存在时, 支撑向量的总数总是大于  $vl$ .

由式(1),  $\frac{1}{vl}$  作为松弛变量  $\xi_i$  的系数, 控制分界面的尺度大小. 考虑两种极端情况, 当  $v$  极小时(本例中  $v \leq 0.04$  的情况),  $\frac{1}{vl}$  极大, 优化的结果为,  $\xi_i = 0, \forall i$ , SVDD 分界面尺度最大, 所有样本点都包含在分界面之

内; 当  $v$  接近 1 时(本例中,  $v > 0.7$  即可), 绝大部分支撑向量为 BSV, 位于 SVDD 分界面之外, 仅有不到  $(1-v)l$  个非支撑向量样本在分界面之内, 分界面尺度最小.

由上述分析可以得出, 当  $v$  值较小时, 所有的样本都包含在 SVDD 分界面之内, 如果有个别远离主样本群, 则为了包含这样的样本, 分界面内势必会包括大片的空白区域, 使得描述精度下降, 误检率增加.  $v$  值较大时, 大量的 BSV 被排除在分界面之外, 又会造成漏检率

较高. 为了达到较高的描述精度和较低的漏检率, 值可选范围为 0.08~0.1.

### 2.3 核函数参数对分界面的影响

这里选择 RBF 核函数作为研究对象. RBF 核函数定义如下:

$$k(x_1, x_2) = \exp\left[-\frac{\|x_1 - x_2\|^2}{2\sigma^2}\right] \quad (9)$$

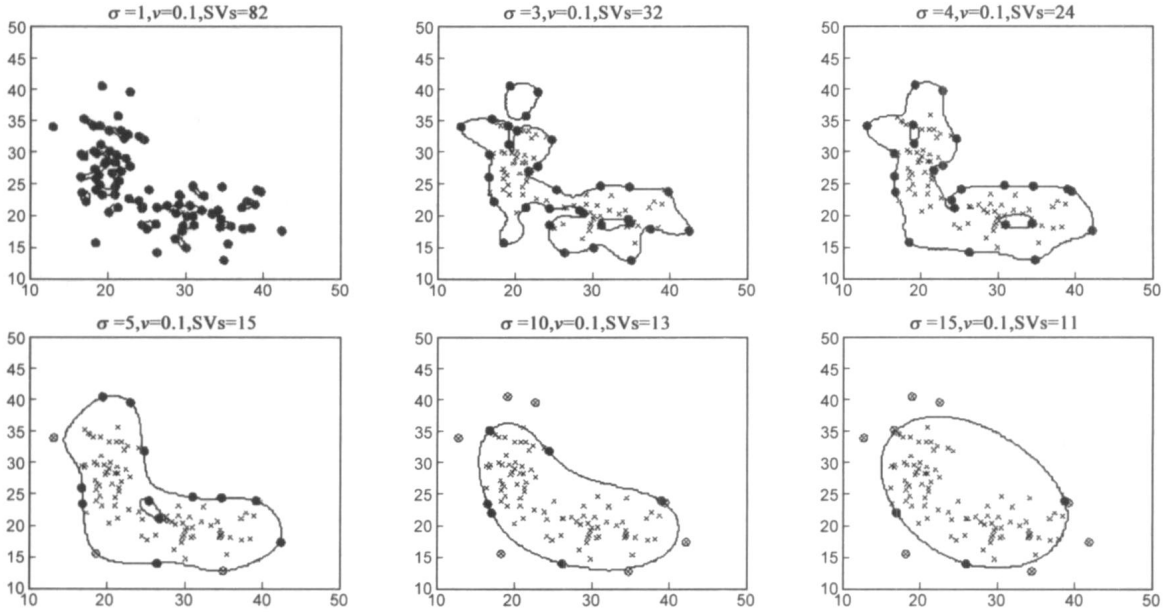


图2 参数σ取不同值时得到的SVDD描述

由图可以看出, 参数  $\sigma$  决定了 SVDD 分界面的复杂程度,  $\sigma$  减小时, 支撑向量的数量增加, 分界面更加贴近训练样本, 虽然提高了描述精度, 但是却损失了一定的推广能力. 取极端情况, 当  $\sigma$  足够小时, SVDD 描述仅包含训练样本, 描述精度达到最高, 却没有任何推广能力.

实际应用时, 较小的  $\sigma \in (3, 5)$  可以得到较高的描述精度和较小的误判率, 而较大的  $\sigma \in (5, 15)$  可以得到较高的推广能力和较小的拒判率.

基于以上两节的分析, 本文提出与 SVDD 描述精度相关的推广能力测度.

### 3 推广能力测度与多层 SVDD 算法

#### 3.1 经典 SVDD 模式识别算法的缺陷

经典 SVDD 模式识别算法流程如下<sup>[2, 5]</sup>:

(1) 设共有  $M$  类, 对每一类样本训练出一个 SVDD 描述  $w_k, k = 1, 2, \dots, M$ ;

(2) 计算测试样本  $z$  与每个  $w_i$  类心的距离. 此处的距离为特征空间内的距离.

$$d_k = k(z, z) - 2 \sum_i \alpha_i k(z, x_{ki}) + \sum_{i,j} \alpha_i \alpha_j k(x_{ki}, x_{kj}) \quad (10)$$

RBF 核可以将样本非线性映射到无限高维空间, 可以处理任意分布的样本, 且仅有一个参数  $\sigma$ , 是应用最为广泛的核函数.

同样以图 1 中月牙形分布的二维数据作为样本,  $v$  值固定为 0.1, 对应不同的参数  $\sigma$ , 可以得到图 2 所示的一组 SVDD 描述. 图 2 中, 'x' 表示训练样本, 加圈点为 BSV, 实心点为 UBSV.

(3) 找出最小的  $d_k$ , 则  $z$  属于第  $k$  类.

此流程主要有两个缺陷, (1) 没有拒判. 与经典 2 类 SVM 一样, 任何测试样本都被识别为已知类别其中之一, 而不存在拒判. 这对实际问题中不属于任何已知类别的样本会造成误判. (2) 该算法的实质为 RBF 核函数将训练样本由原空间映射到特征空间, 并且根据惩罚系数  $v$  (或  $C$ ) 得到各已知类别样本的最小覆盖超球,  $d_k$  即为待测样本与第  $k$  类超球球心的距离. 但对应不同的  $\sigma$ , 特征空间不同, 样本在各空间中的分布关系各不相同, 待测样本在各空间中到各超球球心的距离关系也不固定. 即使在同一个特征空间中, 超球球心的位置还与惩罚系数有关,  $d_k$  的大小关系会随着超球球心的位置的变化而发生变化,  $d_k$  并不是进行样本归属判决的稳定判据.

文[7]在文[2, 5]的基础上提出了归一化距离测度, 即以  $g_k = d_k / \bar{d}_k$  (其中,  $\bar{d}_k$  为第  $k$  类样本中各样本到超球球心的平均距离) 代替  $d_k$  进行归属判决, 解决了各类别样本分布尺度对  $d_k$  的影响, 但两个缺陷仍没有解决.

#### 3.2 基于识别器参数的推广能力测度

对于采用 RBF 核的 SVDD, 本文提出基于  $\sigma$  和  $v$  的推广能力测度  $g = g(\sigma, v, z)$ . 取不同的  $\sigma$  和  $v$  的组合, 可以得到一组包含面积逐渐增大的支撑向量描述域,

如图 3 所示. 图 3(a) 中, 由外到内分别是对应于同一组  $\sigma$  和  $v$  的特征空间中半径由大到小的一组超球在原空间中的投影, 其中, “0” 表示的是 UBSV 所在超球的投影, 即通常得到的 SVDD 描述. 图 3(b) 中, 由外到内分别是  $\sigma$  和  $v$  取 (20, 0.03)、(10, 0.07)、(6, 0.13)、(3, 5, 0.3) 时得到的 4 个 SVDD, 第 2 节关于  $\sigma$  和  $v$  的分析指出,  $\sigma$  的减小以及  $v$  的增大都可以使 SVDD 的描述精度提高, 而且从图 3(b) 中可以看出, 虽然每个支撑向量描述域的面积相差较大, 但是覆盖的样本数量却相差不多(相比与图 3(a), 内层球与外层球覆盖的样本数量上相差较多), 所不同的仅是推广能力上的差异. 内层 SVDD 对应的  $\sigma$  较小  $v$  较大, 推广能力最弱, 覆盖的面积最小; 外层 SVDD 对应的  $\sigma$  较大而  $v$  较小, 推广能力最强, 覆盖的面积最大

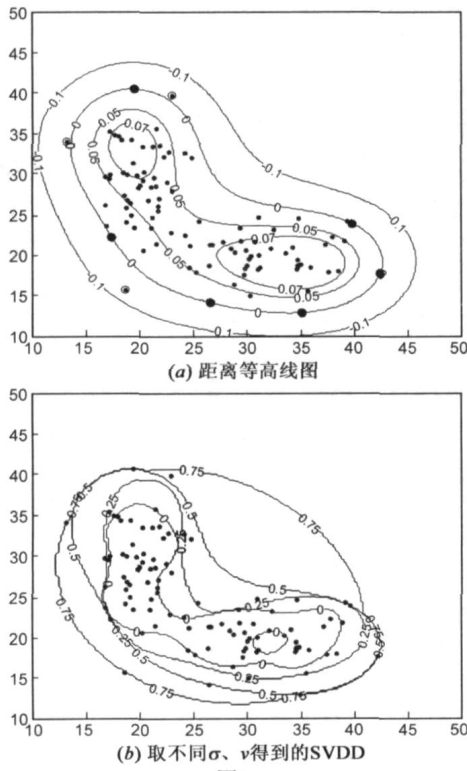


图3

对于一未知类别的样本  $z$ , 总存在一组  $\sigma$  和  $v$ , 其训练得到的支撑向量描述域能刚好包含  $z$ , 即  $z$  对应了一定的推广能力  $g$ .  $z$  越接近内层 SVDD,  $g$  越小, 反之,  $g$  则越大, 与经典方法中的距离测度  $d$  性质类似.

3.1 节指出, 距离测度  $d$  是对应一组特定  $\sigma$  和  $v$  的待测样本与已知类别超球球心的距离关系,  $d$  的性能  $\sigma$  与  $v$  和选取的优劣有关. 而本文提出的推广能力测度  $g$  是针对待测样本  $z$  寻找到最优的  $\sigma$  与  $v$  组合,  $g$  的大小关系, 是待测样本  $z$  与各已知类别样本集合的关系的一种本质上的体现.

相比于计算简单的距离测度  $d$ , 推广能力测度  $g$

的计算困难许多. 我们不可能利用二维搜索的方式确定  $\sigma$  和  $v$ , 因为对应每一组  $\sigma$  和  $v$ , 都需要重新训练一次 SVDD, 其计算量是巨大的, 鉴于此, 本文提出了一种虽降低精度却减小搜索计算量的方法——多层 SVDD.

### 3.3 多层 SVDD

经典 SVDD 模式识别算法中, 起作用的不是每个  $d$  自身的大小, 而是它们之间的关系. 同理, 推广能力测度  $g$  的大小虽然难于计算, 但是只要能得到未知样本属于各类别的  $g$  的大小关系, 一样能够进行模式识别.




图4 待测样本Z与类别A和B的关系图

假设用 3 组  $(\sigma, v)$  分别对两类已知样本  $A$  和  $B$  进行训练, 得到如图 4 所示的关系图,  $z$  为待测样本. 为便于说明, SVDD 被简化为圆形, 而实际上当  $\sigma$  较小时, 支撑向量描述域形状通常很复杂(见图 2). 图 4(a) 中,  $z$  同时被两类的 SVDD 覆盖, 说明  $Z$  属于两类的推广能力测度  $g_A$  和  $g_B$  均小于  $(\sigma_a, v_a)$  所对应的  $g_a$ , 无法决定  $g_A$  与  $g_B$  的大小关系, 图 4(c) 中,  $g_A$  和  $g_B$  均大于  $(\sigma_c, v_c)$  所对应的  $g_c$ , 同样无法决定  $g_A$  与  $g_B$  的大小关系. 图 4(b) 中,  $z$  被  $B$  类覆盖,  $g_B < g_b$ ,  $z$  不被  $A$  类覆盖,  $g_A > g_b$ , 所以  $g_B < g_A$ , 最终可以判决属于  $B$  类.

根据这种使用多个 SVDD 多次对待测样本进行判决的思想, 本文提出了多层 SVDD 的模式识别算法.

算法具体流程如下:

- (1) 指定  $(\sigma_i, v_i)$  作为每一层 SVDD 的参数, 其中,  $i = 1, 2, \dots, N$ ,  $N$  为层数,  $\sigma_1 > \sigma_2 > \dots > \sigma_N, v_1 < v_2 < \dots < v_N$ ;
- (2) 对每一类训练样本, 训练出  $N$  个 SVDD;
- (3) 对待测样本  $z$ , 先用第 1 层的 SVDD 进行判决. 若每一类都不包含, 则拒判, 结束; 若只有一类包含, 则判为此类, 结束; 若有多类包含, 令  $k = 2$ , 跳转(4);
- (4) 对于上一层中包含  $z$  的类别, 用第  $k$  层 SVDD 进行判决. 若每一类都不包含, 则说明样本  $z$  属于每一类的推广能力测度  $g$  处于上一层与本层之间, 此时只能用距离测度进行判决, 结束; 若只有一类包含, 则判为此类, 结束; 若有多类包含, 令  $k = k + 1$ , 跳转(4);
- (5) 若直到最后一层仍有多个类别包含  $z$ , 则使用最后一层的 SVDD 进行距离测度的判决, 结束.

算法中, 训练样本可以是 2 类, 也可以是多类( $> 2$ ). 训练过程的计算量是经典算法的  $N$  倍(每一层都要对各类样本进行二次规划寻优, 但是由于 Hessian 矩阵对于每一类样本是固定的, 仅需求解一次, 所以实际训

练量小于经典算法的  $N$  倍), 识别过程的计算量与经典算法相当(考虑到多类重合的部分毕竟只是少数区域).

算法的重点是层数  $N$  和每层参数的选择. 虽然  $N$  越大, 划分的层次越细, 越能准确地求解出  $g$  的关系, 但是计算量限制了  $N$  不能太大, 实际应用时选择 3~5 较为合适. 第 1 层的参数决定了各类别的最大覆盖范围, 若要降低漏检率,  $\alpha_1$  应尽量大而  $v_1$  应尽量小; 第  $N$  层是最内层, 是所有层中对训练样本描述最精细的一层,  $\alpha_N$  要尽量小. 考虑到各类的重合区域一般都在区域的外层, 所以外层的参数设置要尽量密集一些, 以提高分辨能力.

算法中由于层次划分不够细而不能判决的地方(见步骤 4 和步骤 5)采用距离测度进行最终判决. 考虑到之前已经从大尺度上(即  $g_i \in (g_{k+1}, g_k)$  或者  $g_i \in (0, g_N)$  限定了  $g_i$  的范围, 在这个范围之内, 我们认为距离测度  $d$  与推广能力测度  $g$  有着近似相同的变化规律(见图 3), 所以, 可以用距离测度  $d$  代替推广能力测度  $g$  进行判决.

3.4 实验与分析

为验证本算法的性能, 本文对 5 类飞机缩比模型的一维距离像数据进行识别. 每一类目标的样本个数为 31 个, 分别对应  $0^\circ \sim 30^\circ$  (间隔  $1^\circ$ ) 观测角下的目标的一维距离像. 特征提取的方法是对距离像提取偏度特征、峰度特征、去尺度特征、幅度阈值特征等共 5 个特征组成特征向量.

测试算法的两类识别性能. 任取两类目标的样本(共 62 个), 用添加高斯噪声的方式扩充为 6 倍的样本(每个样本添加 6 次噪声). 在这 372 个样本中, 随机抽取一半作为训练样本, 分别对经典 SVM 分类器(使用 RBF 核)与本算法提出的多层 SVDD 识别器进行训练, 再对剩下的一半样本进行测试. 此实验重复进行 5 次, 正确识别率的均值与方差如下表所示.

表 1 二类分类识别率均值与方差

	类 2		类 3		类 4		类 5	
	F1	SVM	F1	SVM	F1	SVM	F1	SVM
类 1	96.9 (1.6)	99.8 (0.3)	77.5 (3.9)	83.8 (10.5)	84.0 (3.9)	87.9 (4.0)	64.2 (3.1)	74.2 (7.2)
类 2	-	-	93.6 (1.2)	99.3 (0.8)	93.5 (0.7)	90.5 (9.9)	94.9 (1.6)	99.8 (0.2)
类 3			-	-	94.3 (1.0)	97.0 (1.9)	92.2 (2.3)	98.1 (1.9)
类 4					-	-	93.7 (0.8)	98.1 (1.8)

\* 注: F1 表示本文提出的 MLSVDD 算法

实验表明, 在大多数情况下, MLSVDD 的识别率仅略低于 SVM 分类器. 当两类目标相似程度比较高时, 两

种方法的识别率均有所下降, 且方差有所增加. SVM 分类器的识别率方差会增加到 10 左右, 而 MLSVDD 仍能保持在 5 以内, 说明 MLSVDD 的稳定性优于普通二类 SVM 分类器.

MLSVDD 的识别率低于普通二类 SVM 分类器的一个重要原因是 MLSVDD 有拒判的特性. 因此, 为了排除拒判的影响, 我们仅对两种方法的误判率进行统计, 结果如下表.

表 2 二类分类误差及方差

	类 2		类 3		类 4		类 5	
	F1	SVM	F1	SVM	F1	SVM	F1	SVM
类 1	0.1 (0.2)	0.2 (0.3)	21.0 (4.2)	16.2 (10.5)	14.2 (3.5)	12.1 (4.0)	33.7 (2.3)	25.8 (7.2)
类 2	-	-	2.4 (1.0)	0.7 (0.8)	4.2 (0.9)	9.5 (9.9)	1.5 (0.6)	0.2 (0.2)
类 3			-	-	3.4 (1.0)	3.0 (1.9)	5.7 (2.7)	1.9 (1.9)
类 4					-	-	3.9 (0.9)	1.9 (1.8)

\* 注: F1 表示本文提出的 MLSVDD 算法

从表 2 中可以看出, MLSVDD 除了在稳定性上继续保持优势外, 误判率与普通 SVM 分类器的差距也进一步缩小, 有时甚至达到了普通 SVM 分类器的水平.

测试算法的多类识别性能. 取所有类别的样本(共 155 个), 与前一实验类似, 用添加高斯噪声的方式扩充为 6 倍的样本(每个样本添加 6 次噪声). 在这 930 个样本中, 随机抽取一半作为训练样本, 分别对经典分类器与本算法提出的多层 SVDD 识别器进行训练, 再对剩下的一半样本进行测试. 此实验重复进行 5 次, 统计结果如下表.

表 3 多类分类性能

	总识别率	类 1	类 2	类 3	类 4	类 5	训练时间 (秒)	测试时间 (毫秒)
F1	67.5	30.1	74.7	70.1	71.5	90.8	1.95	1.6
F2	67.0	32.2	71.3	70.8	72.2	88.3	1.86	1.6
F3	70.9	44.8	79.5	78.6	80.0	71.3	6.00	3.0
F4	75.3	79.6	99.7	77.6	74.7	45.1	21.31	13.8

\* 注: 表中, F1 为经典 SVDD, 参数  $(\sigma, v)$  为  $(3, 0.1)$ , F2 为经典 SVDD, 参数为  $(15, 0.1)$ , F3 为本文提出的 MLSVDD, 采用 3 层结构, 参数分别为  $(3, 0.1)$   $(5, 0.1)$   $(15, 0.1)$ , F4 为二类 SVM 用一对一方法<sup>[8]</sup>扩展成的多类分类器, 每个二类 SVM 的核函数为 RBF 核.

实验表明, 本文提出的 MLSVDD 识别器识别率高. 虽然训练时间和测试时间相应增加, 却仍远小于用一对一方法扩展而成的多类分类器. 且 MLSVDD 识别器是其中唯一可以进行拒判的分类器.

4 结束语

本文提出了基于 SVDD 推广能力测度的模式识别

方法,对5类飞机缩比模型的一维距离像数据进行了两类分类性能测试与多类分类性能测试,并与相应的经典方法进行比较.实验表明,本方法在保留了经典SVDD算法复杂程度低、运算速度快等优点的同时,有效的提高了识别率,并具备了拒判的功能,具有一定的实用价值.但是,由于缺乏推广能力测度与 $\alpha$ 、 $v$ 关系的直接表达式,只能用多层结构逼近理论值,并用传统距离测度近似估计每层之间各样本的关系.算法中层数以及每层参数均是针对具体应用,参考不同参数的实际分类性能,按照大致相等的能力间隔,在训练前人为指定.目前,作者正在对其进行无监督参数选择研究,并已取得一定成果,将另文发表.

#### 参考文献:

- [1] Vladimir N Vapnik. Nature of Statistical Learning Theory[M]. New York: Springer Verlag, 2000.
- [2] David M J Tax. Support vector data description[J]. Machine Learning, 2004, 54: 45- 66.
- [3] 王守觉. 仿生模式识别(拓扑模式识别)——一种模式识别新模型的理论与应用[J]. 电子学报, 2002, 30(10): 1417- 1420.  
WANG Shou jue. Bionic ( topological) pattem recognition—— a new model of pattern recognition theory and its applications [J]. Acta Electronica Sinica, 2002, 30( 10) : 1417 1420. ( in Chinese)
- [4] Hongliang Jin, Qingshan Liu, Hanqing Lu. Face detection using one class based support vectors[A]. Proceedings of the Sixth IEEE Intemational Conference on Automatic Face and Gesture Recognition ( FGR' 04)[C]. Seoul: IEEE Press, 2004.
- [5] 孙德山, 吴今培. 一类支持向量机在车辆识别中的应用 [J]. 交通运输系统工程与信息, 2003, 3(4): 34- 37.  
SUN De shan, WU Jir pei. Vehicle recognition based on 1 SVM[J]. Joumal of Transportation Systems Engineering and Information Technology, 2003, 3(4): 34- 37. ( in Chinese)
- [6] Scholkopf B. Estimating the support of a high dimensional distribution[J]. Neural Computation, 2001, 13: 1443- 1471.
- [7] Tao Ban. Implementing multi class classifiers by one class classification methods[A]. 2006 International Joint Conference on Neural Networks [C]. Vancouver: IEEE Press, 2006. 327- 332.
- [8] 胡国胜, 钱玲, 张国红. 支持向量机的多分类算法[J]. 系统工程与电子技术, 2006, 28(1): 127- 132.  
HU Guo sheng, QIAN Lin, ZHANG Guo hong. Survey of multi classification algorithms based on support vector machine. Aerospace Electronics Information Engineering and Control, 2006, 28(1): 127-132. ( in Chinese)

#### 作者简介:



朱孝开 男, 1980年7月出生于安徽芜湖, 2002年毕业于南京大学, 现为国防科学技术大学博士研究生, 目前研究方向为红外图象处理, 模式识别.

E Mail: zsk1980@163.com



杨德贵 男, 1978年4月出生于四川崇州, 现为国防科学技术大学博士研究生, 研究方向为红外图象处理, 模式识别.