

# 求解多示例问题的支持向量数据描述方法

方景龙<sup>1</sup>,王万良<sup>2</sup>,王兴起<sup>1</sup>,龙 哲<sup>1</sup>,祁 萌<sup>1</sup>

(1.杭州电子科技大学图形图像研究所,浙江杭州 310018;2.浙江工业大学计算机科学与技术学院,浙江杭州 310023)

**摘 要:** 将支持向量数据描述方法引入到多示例学习中,提出了三种基于 SVDD 的多示例学习方法:基于包分类和示例分类的 SVDD 多示例学习方法 MI-SVDD 和 mi-SVDD,以及基于正示例预测的 SVDD 多示例学习方法 SVDD-MILD-I.在 MUSK 数据集上的实验结果表明,MI-SVDD 方法和 mi-SVDD 方法的精度与 MI-SVM 方法和 mi-SVM 的总体相当,SVDD-MILD-I 方法的精度比较高,超过了我们已知的目前已发表的最好结果;对 COREL 图像库进行基于内容的图像检索的实验表明,SVDD-MILD-I 方法的精度较高,并且比较好地区分了容易混淆的 Beach 类图像与 Mountains 类图像.

**关键词:** 机器学习;模式分类;多示例学习;支持向量数据描述

中图分类号: TN391.4

文献标识码: A

文章编号: 0372-2112(2013)04-0763-05

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2013.04.023

## Support Vector Data Description Method for Solving Multiple Instance Problems

FANG Jing-long<sup>1</sup>, WANG Wan-liang<sup>2</sup>, WANG Xing-qi<sup>1</sup>, LONG Zhe<sup>1</sup>, QI Meng<sup>1</sup>

(1. Institute of Graphic and Image, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;

2. School of Computer Science and Technology, Zhejiang University of Technology, Hangzhou, Zhejiang 310023, China)

**Abstract:** Support Vector Data Description(SVDD)is introduced into multiple instance learning.Three multi-instance learning methods based on SVDD are presented,which include Multiple Instance Learning based on SVDD and bag classification(mi-SVDD)or instance classification(MI-SVDD),and Multiple Instance Learning based on SVDD and positive instance prediction(SVDD-MILD-I).Experimental results on MUSK dataset show that precisions of mi-SVDD and MI-SVDD are quite comparable to those of mi-SVM and MI-SVM;SVDD-MILD-I can get highest accuracy among all the methods known so far.Experimental results in the application of content based image retrieval in COREL image collections demonstrate that precision achieved by SVDD-MILD-I is higher than the others.Additionally,SVDD-MILD-I discriminates the misclassification-prone images between Beach and Mountains quite well.

**Key words:** machine leaning;pattern classification;multi-instance learning;support vector data description

## 1 引言

在多示例学习(multi-instance learning)中,训练集由若干个具有概念标记的包(bag)组成,每个包包含若干个示例(instances).若一个包中至少有一个正示例,则该包被标记为正,若一个包中所有示例都是负示例,则该包被标记为负.多示例学习就是通过对训练包的学习得到一个学习系统,使其尽可能正确地对训练集之外的包的概念标记进行预测.

20世纪90年代,文献[1]在对药物活性预测问题的研究中提出了多示例学习的概念,同时给出了三个求解算法,并利用麝香(MUSK)分子数据进行了实验.在 Dietterich 等人之后,很多研究者开始致力于设计实用的

多示例学习算法.

1998年,文献[2]提出了求解多示例问题的多样性密度(Diverse Density,简称DD)算法.2002年,文献[3]将SVM(Support Vector Machine,支持向量机)方法引入到多示例学习问题中,提出了两种基于SVM的多示例学习算法MI-SVM和mi-SVM.2004年,文献[4]将DD算法与SVM方法相结合提出了DD-SVM方法.2006年,文献[5]提出了求解多示例问题的MILES方法.2009年,文献[6]基于SVM思想在包和示例两个层面上通过关键示例构造了两个凸优化方法来求解多示例学习问题.2010年,文献[7]提出了MILD方法,该方法通过歧义性消除方法和特征映射将问题转化成特征空间中标准的机器学习问题,最后用SVM方法进行求解.

2006年,文献[8]将多示例学习转化成以图为基础的半监督学习,提出了 MISSL 方法.2007年,文献[9]将多示例问题看成一种特殊的半监督学习问题,提出了 MissSVM 方法.2008年,文献[10]认为在不同的应用领域,示例对包标记的影响是不同的,提出一种基于自适应核函数的混合模型来.2009年,文献[11]放弃包中示例都是独立同分布的假设,提出了两种多示例学习算法 MIGraph 和 miGraph.2010年,文献[12]提出了求解多示例学习问题的条件随机场模型 MI-CRF.2011年,文献[13]为了加速大规模多示例学习问题的训练过程,提出了 MILS.

SVDD(Support Vector Data Description,支持向量数据描述)与 SVM 一样,都是核化形式的分类方法<sup>[14]</sup>,并且具有算法复杂程度低、对训练样本数据要求低等优点<sup>[15]</sup>.本文将 SVDD 方法引入到多示例学习的学习中,基于 MI-SVM 和 mi-SVM 的思想<sup>[3]</sup>,提出了两种基于 SVDD 的多示例学习方法:MI-SVDD 和 mi-SVDD;吸收 MILD 方法<sup>[7]</sup>的思想,提出了一种基于 SVDD 的多示例学习方法:SVDD-MILD\_I.

## 2 mi-SVDD 方法和 MI-SVDD 方法

### 2.1 基于包分类的方法 MI-SVDD

给定训练集  $\{X_1, \dots, X_p, X_{p+1}, \dots, X_{p+q}\}$ ,其中  $X_i$  是空间  $R^n$  上有限个样本点组成的集合,称为包. $X_1, \dots, X_p$  为正包,其标记  $Y_1 = \dots = Y_p = 1$ ;  $X_{p+1}, \dots, X_{p+q}$  为负包,其标记  $Y_{p+1} = \dots = Y_{p+q} = -1$ .包中的样本点即为示例,将所有包中的示例依次排列得到示例组成的集合  $\{x_1, \dots, x_r, x_{r+1}, \dots, x_{r+s}\}$ ,其中  $r$  和  $s$  分别是所有正包和所有负包中示例的个数.示例  $x_i$  的标记用  $y_i$  来记,显然  $y_{r+1} = \dots = y_{r+s} = -1$ ,而  $y_1, \dots, y_r$  的值不定.

借鉴 MI-SVM 思想<sup>[3]</sup>,MI-SVDD 方法寻找一个超球  $B(c, R)$  ( $c$  表示球心,  $R$  表示半径)满足:①半径  $R$  尽可能小;②正包中至少有一个正示例被约束在超球内,负包中所有负示例都被约束在超球外.在该方法中,每个包对应一个松弛项  $\xi_i$ ,它求解如下优化问题:

$$\begin{aligned} \min_{R, c, \xi} R^2 + C \sum_{i=1}^{p+q} \xi_i \\ \text{s.t. } Y_i \max_{j \in I(i)} (R^2 - \|\varphi(x_j) - c\|^2) \geq -\xi_i \\ \xi_i \geq 0, \quad i = 1, 2, \dots, p+q \end{aligned}$$

其中  $\varphi(x)$  是核函数,  $I(i) = \{j | x_j \in X_i\}$  为包  $X_i$  中示例的下标集合.

上面的问题不是二次凸规划问题,下面我们通过迭代求解一系列二次凸规划问题来实现它:

Step1(初始化):构建初始训练集  $T = \{\bar{x}_i | i = 1, 2, \dots, p+q\}$ ,其中  $\bar{x}_i = \sum_{j \in I(i)} x_j / |I(i)|, i = 1, 2, \dots, p; \bar{x}_{p+1}$

$$= \arg \min_{x \in X_{p+1}} \left\{ \min_{t \in \{\bar{x}_i | i = 1, 2, \dots, p\}} \|x - t\| \right\}, i = 1, 2, \dots, q.$$

Step2(训练):用带负类的 SVDD 对训练集  $T$  进行如下训练,得到 NSVDD 分类器.

$$\begin{aligned} \min_{R, c, \xi} R^2 + C \sum_{i=1}^{p+q} \xi_i \\ \text{s.t. } Y_i (R^2 - \|\varphi(\bar{x}_i) - c\|^2) \geq -\xi_i \\ \xi_i \geq 0, \quad i = 1, 2, \dots, p+q \end{aligned}$$

Step3(更新):用  $f(x) = R^2 - \|\varphi(x) - c\|^2$  对正包中的示例进行计算,记  $\bar{x}_i = x_{j_i}$ ,其中  $j_i = \arg \max_{j \in I(i)} f(x_j) = R^2 - \|\varphi(x_j) - c\|^2$ .对负包中的示例仍然按照 Step1 中的方式进行选择,然后组建更新后的训练集合  $T = \{\bar{x}_1, \dots, \bar{x}_p, \bar{x}_{p+1}, \dots, \bar{x}_{p+q}\}$ .

Step4(判断):如果训练集合更新前后没有变化,则转 Step5,否则转 Step2.

Step5(结束):输出此时的解  $c, R$ ,得到最终的决策函数  $f(x) = R^2 - \|\varphi(x) - c\|^2$ .

### 2.2 基于示例分类的方法 mi-SVDD

借鉴 mi-SVM 思想<sup>[3]</sup>,mi-SVDD 方法寻找一个超球  $B(c, R)$  满足:①半径  $R$  尽可能小;②正示例被约束在超球内,负示例被约束在超球外.在该方法中,每个示例对应一个松弛项  $\xi_i$ ,它求解如下优化问题:

$$\begin{aligned} \min_{y_i} \min_{R, c, \xi} R^2 + C \sum_{i=1}^{r+s} \xi_i \\ \text{s.t. } y_i (R^2 - \|\varphi(x_i) - c\|^2) \geq -\xi_i, \xi_i \geq 0, \\ \sum_{i \in I(j)} \frac{y_i + 1}{2} \geq 1, \text{ 当 } j = 1, 2, \dots, p \text{ 时;} \\ y_i = -1, \text{ 当 } i = r+1, r+2, \dots, r+s \text{ 时} \end{aligned}$$

这也不是二次凸规划问题,也要通过迭代求解一系列二次凸规划问题来实现.不过,这次的训练样本不再是每个包里选一个示例,而是全部示例都参与,即  $T = \{x_1, \dots, x_r, x_{r+1}, \dots, x_{r+s}\}$ .初始时假定正包中的示例标号  $y_1 = \dots = y_r = 1$ ,然后通过迭代逐步修正正包中的示例标号,最后得到最终的决策函数.

## 3 SVDD-MILD\_I 方法

2010年,文献[7]提出了一种求解多示例问题的方法—MILD.本节,我们借鉴 MILD 方法的思想,提出一种求解多示例问题的 SVDD-MILD\_I 方法,它首先通过某种方式预测正包中的代表性正示例和负包中代表性负示例,然后通过特征映射将问题映射到特征空间,从而将多示例学习问题转化成特征空间中标准的机器学习问题,最后用带负类的 NSVDD 方法进行求解.

### 3.1 正示例预测

根据多示例学习的含义,正包中示例类别标号是不明确的,我们仅仅知道的是它至少包含一个正示例.

因此,本小节的目的就是预测正包中代表性的正示例.

**定义 1** 如果  $t$  是正示例,那么一个示例  $x$  是正示例的概率定义为:

$$P_{x,t} = \Pr(y_x = +1/y_t = +1) = \exp\left(-\frac{\|t-x\|^2}{\sigma_t^2}\right)$$

这里,  $y_t, y_x$  分别表示示例  $t, x$  的类别标记,  $\sigma_t$  是个大于零的参数.

**定义 2** 如果  $t$  是正示例,那么一个包  $X$  是正包的概率定义为:

$$P_{X,t} = \Pr(Y_X = +1/y_t = +1) = \max_{x \in X} P_{x,t} \\ = \max_{x \in X} \exp\left(-\frac{\|t-x\|^2}{\sigma_t^2}\right) = \exp\left(-\frac{d^2(t,X)}{\sigma_t^2}\right)$$

其中  $d(t,X) = \min_{x \in X} \|t-x\|$ .

**定理 1** 如果  $t$  是个正示例,那么当  $\theta_t = \sigma_t \sqrt{2}$  时下面的决策函数与 Bayes 决策理论对包  $X$  的标记相一致.

$$h_{\theta_t}^t(X) = \begin{cases} +1 & d(t,X) \leq \theta_t \\ -1 & \text{otherwise} \end{cases}$$

根据这个定理,如果  $t$  是个正示例,必定存在如上式定义的决策函数能很好地对包进行标记:即正包与  $t$  的距离应该比负包与  $t$  的距离小.

然而,如果  $t$  不是正示例,我们仍然可以按照上式定义决策函数,只不过这个决策函数不能很好地标记包的类别,而恰恰就是这一点成为我们预测正示例的基础.所以从下面开始,我们不要求  $t$  是正示例,即它可以是正示例也可以是负示例.

**定义 3** 若由定理 1 中的决策函数对包  $X_i$  进行标记,  $i = 1, 2, \dots, p+q$ , 则其标记精度定义为

$$P_i(\theta_t) = \frac{1}{p+q} \sum_{i=1}^{p+q} \frac{1 + h_{\theta_t}^t(X_i) Y_i}{2}$$

其中  $Y_i$  为包  $X_i$  的类别标记. 而最优的标记精度为  $P^*(t) = \max_{\theta_t} P_i(\theta_t)$ .

本质上,  $P^*(t)$  反应了用示例  $t$  识别训练包类别的能力,  $P^*(t)$  越大,  $t$  是一个正示例的可能性越大.

**定理 2** 最优标记精度  $P^*(t)$  可以在  $\theta_t$  取之于集合  $\{d(t, X_i) | i = 1, 2, \dots, p\}$  中达到.

根据这个定理,为了估算最优的阈值  $\theta_t^*$ , 我们仅仅需要去计算  $t$  到每个正包的距离.

现在,我们来进行正示例预测<sup>[7]</sup>: 对正包中的示例, 计算最优标记精度  $P^*(x_j)$ ,  $j = 1, 2, \dots, r$ , 则每个包中  $P^*(x)$  最大的示例  $t_i = \arg \max_{x \in X_i} P^*(x)$  即是该包中代表性正示例,  $i = 1, 2, \dots, p$ .

### 3.2 问题求解

上小节预测出了代表性正示例,下面我们在每个负包中选择代表性负示例<sup>[7]</sup>:

$$t_i = \arg \min_{x \in X_i} Q(x), i = p+1, p+2, \dots, p+q$$

其中  $Q(x) = \min_{i \in r^+} \|x - t_i\|$ ,  $T^+ = \{t_i | i = 1, 2, \dots, p\}$ .

对代表性示例作特征映射如下<sup>[8]</sup>:

$$\phi(t_i) = [d(t_i, X_1), d(t_i, X_2), \dots, d(t_i, X_{p+q})], \\ i = 1, 2, \dots, p+q$$

得到训练样本集  $T = \{\phi(t_1), \phi(t_2), \dots, \phi(t_{p+q})\}$ , 这里  $d(t_i, X_j)$  为示例  $t_i$  与包  $X_j$  之间的距离.

最后,我们用带负类的 NSVDD 方法对训练样本集  $T$  进行训练,其优化问题如下:

$$\min_{R, c, \xi} R^2 + C \sum_{i=1}^{p+q} \xi_i \\ \text{s.t. } Y_i(R^2 - \|\varphi(z_i) - c\|^2) \geq -\xi_i, \\ \xi_i \geq 0, \quad i = 1, 2, \dots, p+q$$

这里  $z_i = \phi(t_i)$ .

这个分类器的决策函数形式上是  $f(z) = R^2 - \|\varphi(z) - c\|^2$ . 不过,用这个决策函数进行包  $X$  的类别预测时,需将包  $X$  里的所有示例  $x$  按照  $z = \varphi(x) = [d(x, X_1), d(x, X_2), \dots, d(x, X_{p+q})]$  进行特征映射得到  $z$  后进行, 如果存在一个示例使得  $f(z) = R^2 - \|\varphi(z) - c\|^2 \geq 0$  则判断该包为正包, 否则为负包.

## 4 实验结果及分析

**实验一** 在多示例学习的基准测试数据集 MUSK 上进行, 该数据集可从 UCI 机器学习数据库中提取.

与文献[7]类似, 我们按 1:1 的比率随机地把数据集分成训练集和测试集两部分. 对训练集, 我们采用两倍的随机交叉验证来获得模型中的最优参数, 然后对测试集进行多次测试, 求测试结果的平均值. 在计算中, 采用高斯核函数  $k(x, y) = \exp(-\gamma \|x - y\|^2)$ .

表 1 的计算结果表明 MI-SVDD 和 mi-SVDD 的精度与 MI-SVM 和 mi-SVM 的总体相当; SVDD-MILD\_I 的精度比较高, 在 MUSK1 和 MUSK2 上的分类精度分别为 96.8% 和 95.8%, 超过了我们已知的目前已发表的最好结果 95.6% 和 90.3%.

**实验二** 用 SVDD-MILD\_I 算法进行基于内容的图像检索, 实验图像集来自 COREL 图像库. 该图像库共有 2 000 幅图像, 分为 20 类主题, 每个主题 100 幅. 我们采用一对多的模式对 COREL 图像库中前 10 类主题: C0-Africa、C1-Beach、C2-Building、C3-Buses、C4-Dinosaurs、C5-Elephants、C6-Flowers、C7-Horses、C8-Mountains、C9-Food 的 1000 幅图像进行检索.

包的生成方式同文献[5], 实验方法同实验一. 表 2 给出了 SVDD-MILD\_I 算法计算的分类混淆矩阵, 以及 MILES 算法<sup>[5]</sup> 和 MissSVM 算法<sup>[9]</sup> 的计算结果. 同时, 表 3 列出了表 2 的对角线数据及其均值.

表 1 不同算法在 MUSK 数据集上分类精度(%)

算法	MUSK1	MUSK2
Diverse Density <sup>[2]</sup>	88.9	82.5
MI-SVM <sup>[3]</sup>	77.9	84.3
mi-SVM <sup>[3]</sup>	87.4	83.6
DD-SVM <sup>[4]</sup>	85.8	91.3
MILES <sup>[5]</sup>	86.3	87.7
Ins-KI-SVM <sup>[6]</sup>	84.0	84.4
Bag-KI-SVM <sup>[6]</sup>	88.0	82.0
MILD_I <sup>[7]</sup>	91.1	89.6
MILD_B <sup>[7]</sup>	90.2	86.5
MissSVM <sup>[9]</sup>	87.6	80.0
PPMM KERNEL <sup>[11]</sup>	95.6	81.2
MIGraph <sup>[12]</sup>	90.0	90.0
miGraph <sup>[12]</sup>	88.9	90.3
MI-SVDD	84.2	86.5
mi-SVDD	86.8	87.7
SVDD-MILD_I	96.8	95.8

表 2 分类混淆矩阵

	C0	C1	C2	C3	C4	C5	C6	C7	C8	C9
MILES										
MissSVM										
SVDD-MILD_I										
C0	68.8	1.8	9.3	0.3	1.3	10.3	1.3	4.3	1.3	1.3
	71.6	4.0	3.2	0.4	0.0	10.0	1.2	0.8	2.4	6.4
	83.6	2.4	0.0	3.2	2.8	2.4	1.6	3.2	0.4	0.4
C1	4.0	66.0	4.0	3.6	0.7	3.0	1.3	0.0	15.7	1.7
	3.2	50.0	1.6	6.8	0.0	2.4	0.8	0.0	35.2	0.0
	1.6	80.0	2.4	6.8	2.8	1.6	0.4	2.0	1.6	0.8
C2	4.6	2.0	75.7	4.0	0.7	6.3	0.7	0.3	3.7	2.0
	5.2	10.0	62.4	5.2	0.0	3.6	0.4	0.0	11.6	1.6
	2.0	3.2	76.8	5.6	5.2	1.6	0.0	1.6	3.2	0.8
C3	0.0	2.7	2.3	90.3	0.0	1.0	0.0	0.0	2.0	1.7
	2.4	1.2	3.6	87.2	0.0	0.0	0.0	0.0	1.6	4.0
	0.0	0.0	0.4	99.6	0.0	0.0	0.0	0.0	0.0	0.0
C4	0.0	0.0	0.0	0.0	99.7	0.3	0.0	0.0	0.0	0.0
	0.0	0.0	0.0	0.8	96.4	1.6	0.0	0.0	0.4	0.8
	0.0	1.6	0.4	1.2	92.8	0.8	0.0	0.8	2.0	0.4
C5	2.0	1.3	5.0	0.0	0.7	77.7	0.0	6.6	6.0	0.7
	5.6	2.4	4.0	0.0	0.0	79.2	0.0	0.4	8.4	0.0
	5.2	6.0	1.6	0.4	4.0	74.4	0.0	5.2	1.6	1.6
C6	3.0	0.3	0.0	0.0	0.0	0.0	96.4	0.0	0.0	0.3
	4.0	0.0	1.2	0.4	0.0	0.0	86.4	0.0	1.6	6.4
	0.4	0.0	0.0	1.2	1.6	0.0	90.8	2.4	1.2	2.4
C7	1.0	1.3	0.7	0.0	0.0	1.3	0.7	95.0	0.0	0.0
	6.8	0.8	0.8	0.0	0.0	7.2	0.8	81.6	1.6	0.4
	2.8	0.8	0.0	0.0	0.4	2.0	0.0	92.0	1.2	0.8
C8	3.6	13.7	5.3	1.0	0.3	2.7	1.7	0.7	71.0	0.0
	0.0	13.6	1.6	4.4	0.0	0.8	0.0	0.0	78.4	1.2
	1.2	8.8	6.4	8.8	7.2	2.4	1.2	4.4	58.8	0.8
C9	5.0	1.3	0.3	1.0	0.7	2.3	1.0	2.0	1.0	85.4
	7.6	3.6	0.0	0.4	0.0	1.6	0.0	0.0	0.0	86.8
	0.0	0.0	0.0	2.4	2.0	0.4	0.4	0.0	0.0	94.8

从表 2 可以看出, Beach 类图像与 Mountains 类图像

最容易混淆, 之间的相互错分概率很大, 大多在 13% 以上, 这是因为这两类图像都大量含有 river, lake, ocean 和 sky 等视觉特征相似且语义相关的图像区域, 分类算法很难真正反映它们差异. 但 SVDD-MILD\_I 算法表现较好, 比较好地区分了 Beach 类图像与 Mountains 类图像, Beach 类图像被错分为 Mountains 类图像的概率只有 1.6%, 而 Mountains 类图像被错分为 Beach 类图像的概率也只有 8.8%.

表 3 三种算法在十种目标图像上的检索精度

	MILES	MissSVM	SVDD-MILD_I	均值
C0	68.8	71.6	83.6	74.7
C1	66.0	50.0	80.0	65.3
C2	75.7	62.4	76.8	71.6
C3	90.3	87.2	99.6	92.4
C4	99.7	96.4	92.8	96.3
C5	77.7	79.2	74.4	77.1
C6	96.4	86.4	90.8	91.2
C7	95.0	81.6	92.0	89.5
C8	71.0	78.4	58.8	69.4
C9	85.4	86.8	94.8	89.0
均值	82.6	78.0	84.4	

从表 3 可以看出, Dinosaurs 类图像最容易被检索出来, 被平均检出的概率达 96.3%, 这是因为它的背景最为简单, 与其他九类图像的差别最大. 最难被检出的图像是 Beach 类图像和 Mountains 类图像, 被平均检出的概率只有 65.3% 和 69.4%. 从表 3 还可以看出, 就 10 类图像分类时平均检索精度来说, 表现最好的是 SVDD-MILD\_I, 其平均精度达到 84.4%.

## 5 结论

在 MUSK 数据集上的实验结果表明, MI-SVDD 方法和 mi-SVDD 方法的精度与 MI-SVM 方法和 mi-SVM 的总体相当; SVDD-MILD\_I 方法的精度比较高, 不管是对 MUSK1 还是 MUSK2, 都超过了我们已知的目前已发表的最好结果.

对 COREL 图像库进行基于内容的图像检索的实验表明, SVDD-MILD\_I 算法的精度较高, 其 10 类图像分类时平均检索精度达到 84.4%, 而且比较好地区分了最容易混淆的 Beach 类图像与 Mountains 类图像.

## 参考文献

- [1] Dietterich T G, Lathrop R H, et al. Solving the multiple-instance problem with axis-parallel rectangles[J]. Artificial Intelligence, 1997, 89(1-2): 31-71.
- [2] Maron O, Lozano-pérez T. A framework for multiple-instance learning[A]. Proceedings of the 1997 Advances in Neural Information Processing Systems Conference [C]. Cambridge, MA: MIT Press, 1998. 570-576.

- [3] Andrews S, Hofmann T, et al. Support vector machines for multiple-instance learning [A]. Proceedings of the 2002 Advances in Neural Information Processing Systems Conference [C]. Cambridge, MA: MIT Press, 2003. 561 – 568.
- [4] Chen Y, Wang J Z. Image categorization by learning and reasoning with regions [J]. Journal of Machine Learning Research, 2004, 5: 913 – 939.
- [5] Chen Y, Bi J, et al. MILES: multiple-instance learning via embedded instance selection [J], IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(12): 1931 – 1947.
- [6] Li Y F, Kwok J T, et al. A convex method for locating regions of interest with multi-instance learning [A]. Proceedings of the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases [C]. Bled, Slovenia: Springer, 2009. 15 – 30.
- [7] Li W J, Yeung D Y. MILD: multiple-instance learning via disambiguation [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(1): 76 – 89.
- [8] Rahmani R, Goldman S A. MISSL: multiple-instance semi-supervised learning [A]. Proceedings of the 23rd international conference on Machine learning [C]. New York: ACM, 2006. 705 – 712.
- [9] Zhou Z H, Xu J M. On the relation between multi-instance learning and semi-supervised learning [A]. Proceedings of the 24th international conference on Machine learning [C]. New York: ACM, 2007. 1167 – 1174.
- [10] Wang H Y, Yang Q, et al. Adaptive p-posterior mixture-model kernels for multiple instance learning [A]. Proceedings of the 25th international conference on Machine learning [C]. New York: ACM, 2008. 1136 – 1143.
- [11] Zhou Z H, Sun Y Y, et al. Multi-instance learning by treating instances as non-IID samples [A]. Proceedings of the 26th Annual International Conference on Machine Learning [C]. New York: ACM, 2009. 1249 – 1256.
- [12] Deselaers T, Ferrari V. A conditional random field for multiple-instance learning [A]. Proceedings of the 27th International Conference on Machine Learning [C]. New York: ACM, 2010. 21 – 24.
- [13] Fu Z, Robles-Kelly A, et al. MILIS: multiple instance learning with instance selection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 958 – 977.
- [14] 胡文军, 王士同, 等. 适合大样本快速训练的最大夹角间隔核心集向量机 [J]. 电子学报, 2011, 39(5): 1178 – 1184. HU Wen-jun, WANG Shi-tong, et al. Maximum vector-angular margin core vector machine suitable for fast training for large datasets [J]. Acta Electronica Sinica, 2011, 39(5): 1178 – 1184. (in Chinese)
- [15] 朱孝开, 杨德贵. 基于推广能力测度的多类 SVDD 模式识别方法 [J]. 电子学报, 2009, 37(3): 464 – 469. ZHU Xiao-kai, YANG De-gui. Multi-class support vector domain description for pattern recognition based on a measure of expansibility [J]. Acta Electronica Sinica, 2009, 37(3): 464 – 469. (in Chinese)

#### 作者简介



**方景龙** 男, 1964 年 1 月出生于江西景德镇. 研究员、博士生导师. 1988 年和 2012 年分别在华中理工大学和浙江工业大学获理学硕士和工学博士学位. 主要从事机器学习、信息处理和目标探测等方面的研究工作.

E-mail: fjl@hdu.edu.cn



**王万良** 男, 1957 年 6 月出生于江苏高邮. 教授、博士生导师. 2001 年在同济大学获工学博士学位. 主要从事计算机控制与智能自动化、计算机网络控制系统、智能控制与智能管理分析等方面的研究工作.