

基于超椭圆球分类面的 SVDD 快速决策方法

曲建岭, 王小飞[†], 高峰, 袁涛

(海军航空工程学院 控制系, 山东 青岛 266041)

摘要: 针对现有支持向量数据描述 (SVDD) 快速决策方法在检测不同分布特性的未知样本时分类精度低下的问题, 提出基于超椭圆球分类面的 SVDD (HE-SVDD) 快速决策方法. 该方法通过构建超椭圆球分类面, 提高了不同分布类型数据的分类精度, 同时将 SVDD 的决策复杂度从 $O(n)$ 降低到 $O(2)$ (n 为支持向量数量). 首先研究超球分类面快速决策方法的局限性, 进而给出超椭圆球分类面的构建方法. 在多种数据集上的实验结果表明, HE-SVDD 可以在很大程度上提升现有快速决策方法的分类精度和适用数据类型.

关键词: 支持向量数据描述; 超椭圆球分类面; 快速决策; 分类精度

中图分类号: TP181

文献标志码: A

Fast decision algorithm of SVDD based on hyper-ellipse classification boundary

QU Jian-ling, WANG Xiao-fei[†], GAO Feng, YUAN Tao

(Department of Control, Naval Aeronautical Engineering Institute, Qingdao 266041, China)

Abstract: For some difficult sample sets with different distribution properties, fast decision algorithms of support vector data description (SVDD) may obtain low classification accuracy. Therefore, a fast decision algorithm of SVDD based on the hyper-ellipse classification boundary is proposed, which can reduce the testing complexity from $O(n)$ to $O(2)$ (n is the support vector number). The disadvantages of current decision methods are presented, and then the method of constructing the hyper-ellipse classification boundary is proposed. Experimental results on multi-datasets show that the proposed method can largely improve the classification accuracy and the applicability of existing fast decision algorithms.

Keywords: support vector data description; hyper-ellipse classification boundary; fast decision; classification accuracy

0 引言

支持向量数据描述 (SVDD) 是近年来发展较快的一种单类分类方法^[1-2], 被广泛应用于人脸识别^[3]、故障诊断^[4]和医学图像分类^[5]等各个领域. 标准 SVDD 通过引入核映射使训练样本变得精密可分^[6], 但核化处理不仅增加了 SVDD 训练复杂度, 也使得其决策复杂度依赖于支持向量数量 n . 当前, 改进 SVDD 性能的相关研究主要集中于降低训练复杂度, 主要有: 1) 训练样本规模约减, 包括样本随机分割^[7]、冗余式样本约减^[8]、 K -最远邻近点样本约减^[9]、样本聚类分割^[10]和启发式样本约减^[11]等; 2) 训练规则优化, 包括最小二乘法^[12]、对偶坐标下降法^[13]、自适应学习法^[14]、在线学习法^[15]和增量在线学习法^[16]等. 由于 SVDD 的决策速度对于大规模样本的实时检测至关重要, 本文主要针对 SVDD 的决策复杂度问

题进行研究.

标准 SVDD 的决策复杂度为 $O(n)$, 现有的快速决策方法都是寻找超球球心原像. 其中 FDA-SVDD^[17]和 F-SVDD^[18]算法都是先寻找一个与超球球心矢量方向一致且在输入空间中存在原像的向量; 然后将它的原像作为超球球心在输入空间中的近似原像, 并构建一个刚性超球分类面. 两种算法将 SVDD 的决策复杂度降低为 $O(1)$. 为将 F-SVDD 推广到多聚类中心数据, E-SVDD^[19]算法首先采用聚类思想将训练样本分割为 k 个子集; 然后在各个子集上运用 F-SVDD 算法构建多个超球分类面, 其决策复杂度为 $O(k)$. 上述方法构建的分类面都是输入空间中的刚性超球, 因而只适用于具有特定分布的目标数据集, 泛化能力有限.

针对上述问题, 提出一种基于超椭圆球分类面

收稿日期: 2016-03-03; 修回日期: 2016-06-03.

基金项目: 国家自然科学基金项目 (51505491).

作者简介: 曲建岭 (1968—), 男, 教授, 博士生导师, 从事飞参数据的应用等研究; 王小飞 (1986—), 男, 硕士生, 从事模式识别与智能系统的研究.

[†]通讯作者. E-mail: cody05@163.com

SVDD(HE-SVDD)的快速决策方法,以满足实际应用中样本实时监测对SVDD决策的速度和精度要求.由于HE-SVDD算法的决策过程仅依赖于所构建超椭球分类面的两个焦点,其决策复杂度为 $O(2)$,而超椭球分类面更贴近实际样本分布的特性,在很大程度上提升了现有快速决策方法的适用性和分类精度.

1 SVDD快速决策原理

设 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 为SVDD训练后的支持向量集, $\{\alpha_1, \alpha_2, \dots, \alpha_n\}$ 为各支持向量对应的Lagrange系数, $K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i)\Phi(\mathbf{x}_j))$ 为引进的核函数(常用高斯核 $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/2\sigma^2)$,其基本性质满足 $K(\mathbf{x}_i, \mathbf{x}_j) = 1, \forall i = j, 0 < K(\mathbf{x}_i, \mathbf{x}_j) < 1, \forall i \neq j$).根据定义,SVDD构建的超球球心 \mathbf{c} 和半径 r 分别表示为

$$\begin{cases} \Phi(\mathbf{c}) = \sum_i \alpha_i \Phi(\mathbf{x}_i), 0 < \alpha_i; \\ r^2 = \|\Phi(\mathbf{x}_k) - \Phi(\mathbf{c})\|^2, 0 < \alpha_k < C. \end{cases} \quad (1)$$

其中: C 为平衡参数, \mathbf{x}_k 为满足 $0 < \alpha_k < C$ 的支持向量.SVDD决策未知样本 \mathbf{x} 的方式如下:

$$f(\mathbf{x}) = \|\Phi(\mathbf{x}) - \Phi(\mathbf{c})\|^2 - r^2 = 2 \sum_i \alpha_i K(\mathbf{x}_i, \mathbf{x}_k) - 2 \sum_i \alpha_i K(\mathbf{x}_i, \mathbf{x}). \quad (2)$$

由式(2)可知,SVDD决策未知样本的复杂度为 $O(n)$,在测试大规模样本时耗时过长.为解决这一问题,F-SVDD通过寻找球心原像来降低复杂度.

文献[18]首先在样本空间中寻找一个点 $\hat{\mathbf{x}}$,它的像与超球球心矢量方向相同且距离最近,即满足 $\Phi(\hat{\mathbf{x}}) = \lambda \Phi(\mathbf{c})$ (其中 $\lambda = 1/\|\Phi(\mathbf{c})\|$),可以作为 $\Phi(\mathbf{c})$ 的近似原像.根据文中证明, $\hat{\mathbf{x}}$ 可通过如下方式求取:

$$\min \|\Phi(\hat{\mathbf{x}}) - \Phi(\mathbf{c})\|^2. \quad (3)$$

将式(3)对 $\hat{\mathbf{x}}$ 求偏导并置结果为零,可得

$$\hat{\mathbf{x}} = \frac{\sum_i \alpha_i \mathbf{x}_i K(\mathbf{x}_i, \hat{\mathbf{x}})}{\sum_i \alpha_i K(\mathbf{x}_i, \hat{\mathbf{x}})}. \quad (4)$$

$\hat{\mathbf{x}}$ 与任意样本 \mathbf{x}_i 在高维空间中的欧氏距离为

$$\|\Phi(\mathbf{x}_i) - \Phi(\hat{\mathbf{x}})\|^2 = 2 - 2K(\mathbf{x}_i, \hat{\mathbf{x}}). \quad (5)$$

将 $\Phi(\hat{\mathbf{x}}) = \lambda \Phi(\mathbf{c})$ 代入式(5)左端可以得到

$$\begin{aligned} \|\Phi(\mathbf{x}_i) - \Phi(\hat{\mathbf{x}})\|^2 &= \\ \|\Phi(\mathbf{x}_i) - \lambda \Phi(\mathbf{c})\|^2 &= \\ 2 - 2\lambda \sum_j \alpha_j K(\mathbf{x}_i, \mathbf{x}_j). \end{aligned} \quad (6)$$

联立式(5)和(6)可得

$$K(\mathbf{x}_i, \hat{\mathbf{x}}) = \lambda \sum_j \alpha_j K(\mathbf{x}_i, \mathbf{x}_j). \quad (7)$$

将式(7)代入(4),可以得到 $\hat{\mathbf{x}}$ 的解析表达式

$$\hat{\mathbf{x}} = \frac{\sum_{i,j} \alpha_i \alpha_j \mathbf{x}_i K(\mathbf{x}_i, \mathbf{x}_j)}{\sum_{i,j} \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j)}. \quad (8)$$

将 λ 和 $\hat{\mathbf{x}}$ 代入决策表达式(2),可得

$$f(\mathbf{x}) = \left\| \Phi(\mathbf{x}) - \frac{\Phi(\hat{\mathbf{x}})}{\lambda} \right\|^2 - r^2 = 1 + \frac{1}{\lambda^2} - r^2 - \frac{2}{\lambda K(\mathbf{x}, \hat{\mathbf{x}})}. \quad (9)$$

显然,F-SVDD的决策复杂度为 $O(1)$.

2 基于超椭球分类面的SVDD快速决策

令式(9)中 $f(\mathbf{x}) = 0$,可得F-SVDD的分类面为

$$\|\mathbf{x} - \hat{\mathbf{x}}\|^2 = -2\sigma^2 \ln \left(\lambda \frac{1 + \frac{1}{\lambda^2} - r^2}{2} \right), \quad (10)$$

即F-SVDD构建的是输入空间中的刚性超球分类面.如图1所示,F-SVDD的分类精度随样本类间距的减小不断降低,当样本类间距较小时,会有大量的异常样本落在超球分类面内,从而在很大程度上降低了F-SVDD的分类精度.

2.1 超椭球分类面SVDD

由图1(c)可知,如果能构建一个随目标样本分布特性变化的超椭球分类面,即

$$\sqrt{\|\mathbf{x} - \hat{\mathbf{x}}_1\|^2} + \sqrt{\|\mathbf{x} - \hat{\mathbf{x}}_2\|^2} = 2\bar{R}, \quad (11)$$

则可以在决策复杂度为 $O(2)$ 的前提下显著提高分类精度.其中 $\hat{\mathbf{x}}_1$ 和 $\hat{\mathbf{x}}_2$ 为超椭球分类面的两个焦点, \bar{R} 为长轴半径.

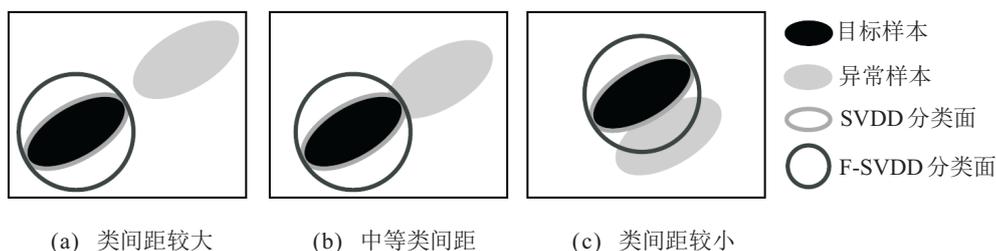


图1 F-SVDD在输入空间中的分类边界

HE-SVDD以F-SVDD计算 $\Phi(c)$ 的近似原像 \hat{x} 为基础,通过寻找离 \hat{x} 的最近点 u 和最远点 v 来计算 \hat{x}_1 和 \hat{x}_2 ,其原理如图2所示.

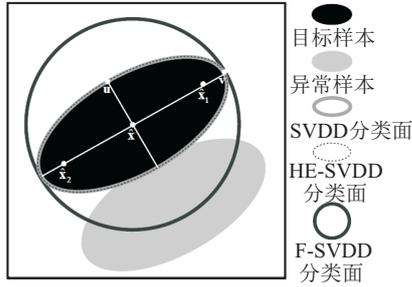


图2 HE-SVDD原理示意图

u 的求解可通过如下最小优化问题来描述:

$$\begin{aligned} \min_u & \|u - \hat{x}\|^2; \\ \text{s.t.} & \|\Phi(u) - \Phi(c)\|^2 = r^2. \end{aligned} \quad (12)$$

代入 $\Phi(c) = \sum_i \alpha_i \Phi(x_i)$,式(12)被简化为

$$\begin{aligned} \min_u & u^T u - 2u^T \hat{x}; \\ \text{s.t.} & \sum_i \alpha_i K(u, x_i) - d = 0. \end{aligned} \quad (13)$$

其中

$$d = \frac{1 + \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) - r^2}{2}.$$

引入拉格朗日函数来去掉约束项,即

$$L(u) = u^T u - 2u^T \hat{x} - \mu \left(\sum_i \alpha_i K(u, x_i) - d \right), \quad (14)$$

其中 μ 为约束式的拉格朗日乘子.置 $\partial L / \partial u = 0$,可得

$$\mu = \frac{u - \hat{x}}{\sum_i \alpha_i (u - x_i) K(u, x_i)}. \quad (15)$$

将式(15)代入(14),可以得到(12)的非约束优化形式.然后采用大规模机器学习算法中普遍使用的随机梯度下降(SGD)法^[20]来快速求解 u ,其求解方式如下:

$$u_{t+1} = u_t - \eta_t \nabla_u L(u_t, x_t). \quad (16)$$

其中: t 为迭代次数, u_t 为 u 的瞬时值, $\eta_t = a/(A + t)^\lambda$ 为学习速率^[21], x_t 为随机抽取的任一支持向量, $\nabla_u L(u_t, x_t) = \partial L(u_t, x_t) / \partial u$ 为 $L(u)$ 的瞬时梯度,其具体表达式为

$$\begin{aligned} \nabla_u L(u_t, x_t) = & 2(u_t - \hat{x}) - (a_t(\kappa_t + 2(u_t - \hat{x})^T a_t) - \\ & d(\kappa_t + d/n + 2\xi)(u_t - \hat{x})) / (a^T a_t). \end{aligned} \quad (17)$$

式(17)中各瞬时量表达式如下:

$$\begin{cases} a_t = \alpha_t (u_t - x_t) K(u, x_t), \\ \kappa_t = K(u_t, x_t) - \frac{d}{n}, \\ \xi_t = \alpha_t (u_t - x_t)^T (u_t - x_t) K(u_t, x_t). \end{cases} \quad (18)$$

其中: a_t 为瞬时向量, κ_t 和 ξ_t 为瞬时常量, u 通过式(16)求取.

同 u 类似, v 可以通过如下最优化问题来求取:

$$\begin{aligned} \max_v & \|v - \hat{x}\|^2; \\ \text{s.t.} & \|\Phi(v) - \Phi(c)\|^2 = r^2. \end{aligned} \quad (19)$$

接下来的问题是根据 \hat{x} , u 和 v 求输入空间超椭球分类面的两个焦点 \hat{x}_1 和 \hat{x}_2 .首先计算超椭球体的短轴 \bar{r} 和长轴半径 \bar{R} ,即分别计算 u 和 v 到 \hat{x} 之间的欧氏距离

$$\begin{cases} \bar{r} = \sqrt{\|u - \hat{x}\|^2}, \\ \bar{R} = \sqrt{\|v - \hat{x}\|^2}. \end{cases} \quad (20)$$

进而可以得到两个焦点 \hat{x}_1 和 \hat{x}_2 到 \hat{x} 之间的欧氏距离,均为 $l = \sqrt{\bar{R}^2 - \bar{r}^2}$.

考虑到 \hat{x}_1 , \hat{x}_2 与 v 在以 \hat{x} 为原点的欧氏空间中具有相同的矢量方向,故可通过下式计算:

$$\begin{cases} \hat{x}_1 = \hat{x} - \frac{l}{\bar{R}(\hat{x} - v)}, \\ \hat{x}_2 = \hat{x} + \frac{l}{\bar{R}(\hat{x} - v)}. \end{cases} \quad (21)$$

将 \hat{x}_1 , \hat{x}_2 和 \bar{R} 代入式(11),即可得到构建的超椭球分类面,则测试样本 x 的决策函数变为

$$f(x) = \sqrt{-\ln K(x, \hat{x}_1)} + \sqrt{-\ln K(x, \hat{x}_2)} - 2R. \quad (22)$$

当 $f(x) \leq 0$ 时, x 被接受为目标样本,否则 x 为异常样本.显然HE-SVDD的决策复杂度为 $O(2)$.

考虑到实际应用训练样本分布的不完备性,直接由式(20)计算的 \bar{r} 可能偏小,进而造成部分边缘目标样本未被构建的分类面覆盖.因而,将式(22)的刚性分类面改进为 \bar{r} 根据实际样本分布变化的柔性分类面,即

$$l = \sqrt{\bar{R}^2 - k\bar{r}^2}, \quad (23)$$

其中 $1 \leq k \leq \bar{R}^2 / \bar{r}^2$ 为调整系数.

显然 $k = \bar{R}^2 / \bar{r}^2$ 时,HE-SVDD和F-SVDD构建的分类面等同,此时 $\hat{x}_1 = \hat{x}_2 = \hat{x}$.实际训练过程中,不断调整 k 值到目标样本的识别率为 $1 - 1/Cm$ (其中 $1/C$ 为估算的异常样本数目^[2], m 为训练样本总量),从而使HE-SVDD的分类性能达到最佳.

2.2 HE-SVDD算法

HE-SVDD算法步骤具体如下:

Step 1:用标准SVDD算法学习训练集,根据式(8)

计算 \hat{x} ;

Step 2: 根据式(16)的SGD法求解 u 和 v ;

Step 3: 根据式(21)和(22)建立超椭球分类面;

Step 4: 调整 k 值并重复 Step 3, 直到目标样本识别率为 $1 - 1/Cm$;

Step 5: 采用式(22)来决策未知样本.

2.3 有效性验证

为说明 HE-SVDD 在类间距较小数据集上的有效性, 在由 Prtools 工具箱随机生成的 Difficult 数据集上进行验证实验. 其中目标样本被用作训练集,

异常样本被用来进行对比分析, 两类样本规模均为 200. 图 3 给出了不同 k 值下的 HE-SVDD 分类面. 可以看出, 当 k 较小时 ($k = 1$), 部分目标样本落在分类面外, HE-SVDD 的分类面同 SVDD 差异较大; 当 k 增大到一定程度时 ($k = 1.5$), 正常样本和异常样本的接受率达到一个折中, 此时 HE-SVDD 的分类性能达到最优, 与 SVDD 最接近; 当 k 值较大时 ($k = 2$), 异常样本的错误接受率明显高于目标样本的正确接受率, 导致 HE-SVDD 的分类性能迅速恶化. 结合图 1(c) 可知, F-SVDD 构造的刚性超球分类面在 Difficult 数据

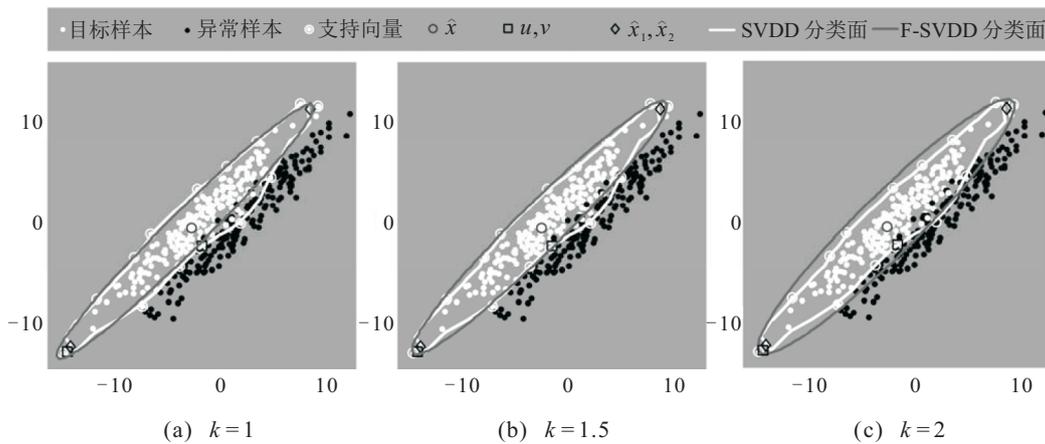


图 3 Difficult数据集上的HE-SVDD分类面

表 1 UCI数据集分类结果

数据集	类别	测试时间/s			分类精度/%		
		E-SVDD	F-SVDD	HE-SVDD	E-SVDD	F-SVDD	HE-SVDD
Blood	1	0.84	0.50	0.76	75.00	71.12	79.03
	2	0.57	0.25	0.44	80.79	76.67	84.65
Breathc	1	0.71	0.38	0.56	81.68	70.15	83.41
	2	0.70	0.40	0.59	80.24	77.88	82.06
Cmc	1	1.03	0.45	0.71	56.35	54.77	56.35
	2	0.94	0.33	0.60	70.18	69.38	70.14
	3	0.87	0.32	0.58	69.38	68.07	69.34
Iris	1	0.04	0.03	0.05	97.22	97.23	98.24
	2	0.05	0.03	0.03	93.88	91.98	95.88
	3	0.04	0.03	0.05	93.08	92.20	93.01
Liver	1	0.54	0.21	0.30	54.62	54.01	57.85
	2	0.62	0.23	0.32	69.42	67.83	71.80
Waveform	1	1.32	0.66	1.04	88.44	82.83	89.23
	2	1.55	0.68	90.67	83.51	1.22	92.09
	3	1.43	0.60	90.10	82.55	1.26	91.48
Wine	1	0.19	0.12	0.18	88.38	85.34	88.07
	2	0.17	0.14	81.76	0.18	77.68	86.25
	3	0.18	0.13	86.32	0.17	83.16	89.72

集上并不适用,具有较高的异常样本接受率.

上述结果表明,HE-SVDD不但可以显著提升现有SVDD快速决策方法的分类性能,而且仍然能够保持较小的决策复杂度.

3 实验结果与分析

本节分别采用UCI数据集和Mnist数据集来验证HE-SVDD的性能. F-SVDD和E-SVDD两种快速决策算法被用来进行对比分析. 分类精度由ROC曲线下的面积(AUC)来衡量, AUC取值范围为0~1, 取值越大代表分类性能越好. 实验计算机配置为1.6 GHz CPU 和2 GB RAM. 实验中 C 和 σ 均采用10折交叉验证法来确定, 其中 C 的选取范围为 $2^{-2} \sim 2^2$, σ 的选取范围为 $2^{-4} \sim 2^4$. 同文献[21], 学习速率 η_t 中的参数设置为 $\lambda = 1$ 和 $A = 20$, 而 a 由10折-验证法来选取, 范围为 $10^{-2} \sim 10^2$. 所有结果均为10次重复实验的均值.

3.1 UCI数据集实验

本节使用Blood等7种UCI数据来验证HE-SVDD的适用性, 它们的特征维数、包含种类和数据规模等各不相同^[8]. 依次以各数据集中的一类为目标样本, 并随机抽取其中的50%为训练集, 全部剩余样本为测试集. 实验过程中首先采用标准SVDD进行训练, 然后对获取的支持向量集进行处理来构建快速决策分类面. 表1给出了E-SVDD、F-SVDD和HE-SVDD三种快速决策算法在7种UCI数据集共18个目标类上的测试时间和分类精度实验结果, 其中加粗字体表示最优的测试时间或分类精度.

从测试时间来看, HE-SVDD相对于F-SVDD增加了少量时间, 但其速度明显高于E-SVDD. 从分类精度来看, 在7种UCI数据集共18个目标类中, HE-SVDD在其中13个目标类上获取了最优分类精度, 在剩余5个目标类中获得了与E-SVDD相当的分精度. 上述结果表明, F-SVDD直接采用刚性超球决策面进行分类, 对数据集分布特征要求较高, 分类精度较低; E-SVDD只在一定程度上提升了F-SVDD的分类精度; HE-SVDD采用与数据集分布特征相关的柔性超椭圆分类面, 灵活性较高, 因而有效扩展了现有快速决策方法的适用数据类型, 并明显提升了分类精度.

3.2 Mnist数据集实验

为验证HE-SVDD在大规模高特征维数据集上的性能, 选用Mnist手写数字图像数据集(训练样本和测试样本的数目为60 000和10 000, 均为 28×28 像素的数字图像)来进行对比实验. 依次以训练集中的

0~9为目标样本, 测试集固定不变. 图4为Mnist数据集各目标类前10个手写数字图像的样本示例.



图4 Mnist手写数字图像

由于Mnist数据集规模较大且维度较高, 直接采用标准SVDD算法训练时间过长, 首先采用文献[15]的在线SVDD进行训练, 然后分别采用3种快速决策算法对获取的支持向量集进行处理来构建快速决策分类面. 表2给出了实验结果. 可以看出, 测试效率的实验结果同UCI数据集基本一致, 而从测试精度上来看, F-SVDD的性能最差, 在全部10个目标类上均为最低, E-SVDD虽然相对F-SVDD有所改进, 但它只在1和3共2个目标类上取得了与HE-SVDD相当的精度, 在剩余8个目标类上, HE-SVDD的分类精度要明显优于F-SVDD和E-SVDD. Mnist数据集实验结果表明, HE-SVDD在大规模高特征维数据集上同样具有较高的分类精度和稳定性, 适用于大规模数据的快速检测.

表2 Mnist数据集实验结果

类别	测试时间/s			分类精度/%		
	E-SVDD	F-SVDD	HE-SVDD	E-SVDD	F-SVDD	HE-SVDD
0	6.02	2.79	4.23	90.18	90.35	92.55
1	7.36	3.32	6.04	89.42	88.59	89.39
2	5.16	2.21	3.98	93.61	91.34	96.48
3	5.91	2.98	5.29	97.06	90.70	96.89
4	6.56	2.83	5.32	88.72	88.58	91.97
5	5.03	2.60	4.67	86.63	85.76	93.21
6	5.07	2.17	4.13	87.44	86.69	94.07
7	6.50	2.84	5.10	89.03	85.02	93.05
8	4.25	2.68	3.64	94.06	92.09	97.34
9	5.06	2.71	4.80	92.49	91.78	95.33

UCI和Mnist数据集的实验结果综合表明, HE-SVDD在保持较快决策速度的前提下明显改善了现有SVDD快速决策方法的分类精度, 具有较好的泛化和推广能力.

4 结论

实际应用中经常面临着大规模数据的快速检测问题, 这对SVDD的决策时间提出了较高的要求. 现

有的F-SVDD和E-SVDD等快速决策算法都可以在很大程度上降低SVDD的决策复杂度,但由于它们构建的都是刚性超球分类面,其适用数据类型和分类精度都非常有限.本文以F-SVDD为基础构建了一个泛化能力更强的超椭圆分类面,用于未知样本的快速决策问题.测试实验结果表明,HE-SVDD算法可以在保持较高决策速度的基础上,显著提升现有快速决策方法的数据适用类型和分类精度,因而更加适用于实际大规模未知样本的快速检测问题.

参考文献(References)

- [1] Markou M, Singh S. Novelty detection: A review, Part 1: Statistical approaches[J]. Signal Processing, 2003, 83(12): 2481-2497.
- [2] Tax D, Duin R. Support vector data description[J]. Machine Learning, 2004, 54(1): 45-66.
- [3] Liu B, Xiao Y S, Cao L B, et al. Svdd-based outlier detection on uncertain data[J]. Knowledge and Information Systems, 2013, 34(3): 597-618.
- [4] 唐明珠, 王岳斌, 阳春华. 一种改进的支持向量数据描述故障诊断方法[J]. 控制与决策, 2011, 26(7): 967-982.
(Tang M Z, Wang Y B, Yang C H. Modified support vector data description for fault diagnosis[J]. Control and Decision, 2011, 26(7): 967-982.)
- [5] Camastra F, Verri A. A novel kernel method for clustering[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2005, 27(5): 801-805.
- [6] Lee S, Park J. Low resolution face recognition based on support vector data description[J]. Pattern Recognit, 2006, 39(9): 1809-1812.
- [7] Luo J, Li B, Wu C Q, et al. A fast SVDD algorithm based on decomposition and combination for fault detection[C]. IEEE Int Conf on Control and Automation. Xiamen, 2010: 1924-1928.
- [8] Na S G, Kim J S, Han I J, et al. Study on data reduction technique for incremental training of SVDD[C]. Int Conf on Environment and Electrical Engineering. Venice, 2012: 627-631.
- [9] Xiao Y, Liu B, Hao Z, et al. A K -farthest-neighbor-based approach for support vector data description[J]. Advances in Adaptive Data Analysis, 2014, 1(1): 1-41.
- [10] Kim P, Chang H, Song D, et al. Fast support vector data description using k -means clustering[J]. In advances in Neural Networks — ISNN, 2007: 506-514.
- [11] 曲建岭, 孙文柱, 邸亚洲, 等. 面向新异检测的启发式约减支持向量描述[J]. 控制与决策, 2014, 29(10): 1783-1787.
(Qu J L, Sun W Z, Di Y Z, et al. Heuristic reduction support vector data description for novelty detection[J]. Control and Decision, 2014, 29(10): 1783-1787.)
- [12] Choi Y S. Least squares one-class support vector machine[J]. Pattern Recognition Letters, 2009, 30(13): 1236-1240.
- [13] Chang K W, Hsieh C J, Lin C J. Coordinate descent method for large-scale L_2 -loss linear SVM[J]. J of Machine Learning Research, 2008, 9: 1369-1398.
- [14] Khazai S, Safari A, Mojaradi B. A fast-adaptive support vector method for full-pixel anomaly detection in hyperspectral images[C]. IEEE Geoscience and Remote Sensing Symposium. Vancouver, 2011: 1763-1766.
- [15] Tax D, Laskov P. Online SVM learning: From classification to data description and back[J]. Neural Networks and Signal Processing, 2003, 1: 499-508.
- [16] Tavakkoli A, Nicolescu M, Bebis G, et al. Efficient background modeling through incremental support vector data description[C]. Int Conf on Pattern Recognition. Tampa FL, 2008: 1-4.
- [17] 胡文军, 王士同. SVDD的快速实时决策方法[J]. 自动化学报, 2011, 37(9): 1085-1094.
(Hu W J, Wang S T. Fast real-time decision approach of support vector data description[J]. Acta Automatica Sinica, 2011, 37(9): 1085-1094.)
- [18] Liu Y H, Liu Y C, Chen Y J. Fast support vector data descriptions for novelty detection[J]. IEEE Trans on Neural Networks, 2010, 21(8): 1296-1313.
- [19] Peng X, Xu D. Efficient support vector data descriptions for novelty detection[J]. Neural Computing and Applications, 2012, 21(8): 2023-2032.
- [20] Plakhov A, Cruz P. A stochastic approximation algorithm with step-size adaptation[J]. J of Mathematical Sciences, 2004, 120(1): 964-973.
- [21] Klein S, Pluim J, Staring M, et al. Adaptive stochastic gradient descent optimisation for image registration[J]. Int J of Computer Vision, 2009, 81(3): 227-239.

(责任编辑: 孙艺红)