

基于 KKT 条件与壳向量的增量学习算法研究

文 波 单甘霖 段修生

(军械工程学院光学与电子工程系 石家庄 050003)

摘 要 针对经典支持向量机难以快速有效地进行增量学习的缺点,提出了基于 KKT 条件与壳向量的增量学习算法,该算法首先选择包含所有支持向量的壳向量,利用 KKT 条件淘汰新增样本中无用样本,减小参与训练的样本数目,然后在新的训练集中快速训练支持向量机进行增量学习。将该算法应用于 UCI 数据集和电路板故障分类识别,实验结果表明,该算法不仅能保证学习机器的精度和良好的推广能力,而且其学习速度比经典的 SMO 算法快,可以进行增量学习。

关键词 机器学习,支持向量机,增量学习,KKT 条件,壳向量

中图分类号 TP391, TN95 **文献标识码** A

Research of Incremental Learning Algorithm Based on KKT Conditions and Hull Vectors

WEN Bo SHAN Gan-lin DUAN Xiu-sheng

(Department of Optical and Electronic Engineering, Ordnance Engineering College, Shijiazhuang 050003, China)

Abstract Because the classical support vector machine is difficult to realize incremental learning fleetly and rapidly when the number of training samples gets larger, this thesis proposed an incremental learning algorithm based on KKT conditions and hull vectors. This algorithm first selects the hull vectors which contain all support vectors. Next, it eliminates the useless samples among newly-added ones by using KKT conditions in order to reduce the number of training samples, then starts increment learning. The experimental results show that this algorithm not only guarantees the precision and good generalization ability of the learning machine, but also faster than the classical SVM algorithm. Therefore, it can be used in incremental learning.

Keywords Machine learning, Support vector machine, Incremental learning, KKT conditions, Hull vectors

1 引言

支持向量机(SVM)^[1]是 Vapnik 等人在统计学习理论的基础上提出的一种普适学习机模型,它采用核函数映射实现了非线性 SVM,从而增强了学习机的性能。目前, SVM 越来越受到广泛的重视,国际上形成了对其研究的热潮^[2,3]。机器学习是人工智能领域的基本问题,在学习初期许多学习系统所能获得的样本量较少,随着时间的推移与样本的不断累积,系统的工作效率降低,这时需要新增的样本参与学习训练,以提升系统的性能。标准 SVM 不具备增量学习能力,因此研究有效增量学习方法具有重要的意义。

Syed^[4]对样本集的支持向量进行了分析,提出了一种简单支持向量机增量学习算法。该算法每次只保留支持向量,其与新增样本一起形成新的样本集进行增量训练,得到最终的决策函数和支持向量集,该方法在增量训练中抛弃了所有非支持向量,降低了运算的复杂度,但同时也抛弃了非支持向量样本中所包含的有用的分类信息。申晓勇^[5]基于 SVM 寻优问题的 Karush, Kuhn, Tucker(KKT)条件和样本之间的关系,提出了基于 SVM 的计数器淘汰算法。徐海龙^[6]利用各

样本的中心距离与其到最优超平面距离之间的关系,提出一种基于距离比值的增量训练算法,该算法在增量学习过程中能够淘汰那些对最优决策函数影响不大的少数样本。文献[7-9]也提出了一些基于支持向量机的增量学习算法。通过总结与归纳,这些算法都存在一个共同的特征,即需要对全部的历史样本进行学习,这需要大量的存储空间,直接影响到后继增量学习的效率。如何从历史样本集和新增样本集中提取少而有价值的样本,而非全部样本进行训练,是个值得研究的问题。

对样本的空间几何分布研究得知,在空间中样本呈聚类分布,不同类别样本将分布在不同的区域,聚类边缘的样本称为壳向量,SV 就在其中产生,也就是说壳向量不一定是 SV,但 SV 一定是壳向量。覃俊^[10]提出了一种基于壳向量的增量式支持向量机快速学习算法。该算法利用计算几何的知识在样本中选取一部分最有可能成为支持向量的样本即壳向量,作为新的训练样本集,再进行支持向量训练。该方法很大程度上减少了求取支持向量过程中的二次优化运算时间,使增量学习的训练速度大为提高。但利用该方法提取的壳向量只适用于解决线性空间中的两分类问题,且按照该算法提取出

到稿日期:2012-05-31 返修日期:2012-11-09 本文受国防预研基金项目(9140A27020211JB3402)资助。

文 波(1987—),男,硕士生,主要研究方向为机器学习、电子装备故障诊断等, E-mail: wenchuan321@126.com; 单甘霖(1962—),男,教授,博士生导师,主要研究方向为机器学习、信息融合等; 段修生(1971—),男,博士,副教授,主要研究方向为模式识别、电子装备故障诊断等。

的壳向量并不能包含所有可能成为支持向量的样本,分类精度不能得到保证,在实际应用中不具有推广性。吴崇明^[11]从几何角度出发提出了一种基于类边界壳向量的快速 SVM 增量学习算法,该方法先利用样本分布几何信息求出当前训练样本集的壳向量,再利用中心距离比值法选择出类与类之间边界上的壳向量,将类边界壳向量与新增样本一起作为新的训练样本集参与训练。此法很大程度约简了训练样本集的规模,减少了训练时间,但利用中心距离比值法选择类边界壳向量时依赖主观阈值的选择,阈值选择不好将淘汰部分包含重要历史信息的样本,从而降低分类精度。文献[12-14]也分别介绍了一些基于壳向量的增量学习算法,这些算法大体上都存在如下共同缺点:一是部分算法是基于线性空间中的两分类情况所提出的;二是部分算法在淘汰无用样本时选择的方法需要主观确定阈值,新的样本集容易丢失重要历史信息。

本文在上述研究的基础上,利用历史样本集的几何信息,通过预提取样本集中包含所有支持向量的壳向量,借助支持向量的思想,对壳向量进行初始训练。对分批进入的新增样本集,利用 KKT 条件与样本的关系,选择新增样本集中违反决策函数的 KKT 条件的样本加入增量学习,不断修正所得到的决策函数,直至增量学习过程结束,得到最终的决策函数。实验结果表明,本文算法不仅保证了学习机器的精度,而且显著地提高了学习的速度,具有良好的推广能力。

2 问题的描述

2.1 支持向量机及 KKT 条件^[15]

支持向量机源于线性情况下的分类问题,利用支持向量机分类的目的就是要寻找最优超平面,最优超平面就是最大间隔超平面,即在将两类样本正确分类的同时,使得分类间隔最大,如图 1 所示。




图 1 最优分类超平面示意图

通过求解凸半正定二次规划:

$$\begin{aligned} \max W(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) \\ \text{s. t. } C &\geq \alpha_i \geq 0, \sum_{i=1}^l y_i \alpha_i = 0 \end{aligned} \quad (1)$$

式中, $K(x_i, x_j)$ 为核函数。得到的 SVM 分类器的决策函数为:

$$f(x, \alpha) = \text{sign}(\sum_{\text{支持向量}} y_i \alpha_i K(x_i, x_j) + b) \quad (2)$$

在分类学习中只有支持向量的样本才对最优超平面和决策函数有贡献,即支持向量集能够充分描述整个训练样本集的特征,对它的划分等价于对整个样本集的划分。大多数情

况下,支持向量只占训练样本集的很少一部分,因此可以使用支持向量集取代训练样本集进行学习,以在不影响分类精度的同时降低训练时间及存储空间。

对于上述问题, α 是拉格朗日乘子,当且仅当对每一个 x 都满足 KKT 条件时, $\alpha = [\alpha_1, \dots, \alpha_l]$ 才是上述规划的最优解:

$$\begin{cases} \alpha_i = 0 \rightarrow y_n f(x_n) > 1 \\ 0 < \alpha_i < C \rightarrow y_n f(x_n) = 1 \\ \alpha_i = C \rightarrow y_n f(x_n) < 1 \end{cases} \quad (3)$$

即

$$\begin{cases} \alpha_i = 0 \rightarrow f(x_n) > 1 \text{ 或 } f(x_n) < -1 \\ 0 < \alpha_i < C \rightarrow f(x_n) = 1 \text{ 或 } f(x_n) = -1 \\ \alpha_i = C \rightarrow -1 < f(x_n) < 1 \end{cases} \quad (4)$$

式中, $f(x) = 0$ 为分类面, $f(x) = \pm 1$ 为分类间隔的边界。 $\alpha = 0$ 对应的样本分布在 SVM 分类间隔外, $0 < \alpha < C$ 的样本位于 SVM 分类间隔上, $\alpha = C$ 的样本位于 SVM 分类间隔内。

文献[6]中的证明表明,新增训练样本违背 KKT 条件的充要条件为新增样本位于 $y_n f(x_n)$ 区域中。

2.2 壳向量及壳向量的提取

定义 1 包含某一类训练集的最小凸集(一般是多面体)称为训练集的凸壳,以下简称凸壳。

定义 2 壳向量^[16]就是训练集凸壳的极点。

通过对 SVM 机理的分析可知,在线性可分情况下, SVM 算法通过寻找支持向量,可在两类样本间形成一个能够保证分类准确且分类间隔最大的最优分类超平面。对于非线性可分情况,则可将原始训练空间映射到高维空间,使样本集在该空间线性可分。从几何角度看,最优分类面的位置由支持向量决定,为保证其满足使两类样本间最小间隔最大化的条件,支持向量只可能是位于每一类训练样本集几何意义上最边缘的点,而不可能是训练样本集内部的点。

壳向量反映了训练样本集的几何结构信息,支持向量就在其中产生,壳向量集合是由训练样本集中最有可能成为支持向量的样本构成的,它是支持向量集的一个规模较小的超集^[17]。同时壳向量集合中也包含了所有违背 KKT 条件可能成为支持向量的样本,用壳向量集合代替原训练样本集进行 SVM 训练,在不影响分类精度的情况下,可以缩减求解问题的规模,从而加快训练速度,对于一个训练集,其壳向量的求取思路如下。

假设 $X = \{x_1, x_2, \dots, x_l\}$ 是给定的训练集, X_{κ} 是 X 在特征空间上的凸壳, V 是凸壳 X_{κ} 的极点集合(即为壳向量集合)。用函数 $F(x, V)$ 来判断 x 是否为由 V 确定的凸壳的内点,若 x 是其内点则 $F(x, V) = \text{true}$, 否则 $F(x, V) = \text{false}$ 。用 V_0 来表示可能为极点的集合, $V \subseteq V_0$ 。求壳向量集合 V 的思想是首先求出包含给定点集的最小超球,再以这个超球面上的点作为初始壳向量,然后通过迭代方法求出可能的极点集合 V_0 , 再从 V_0 中逐步去掉一些多余的点,从而求出凸壳的极点集合(即壳向量集合),引入非线性映射 φ 和核函数 $k(x, y) = \varphi(x) \cdot \varphi(y)$, 给出特征空间(当核函数为线性核函数时即为原空间)中凸壳的极点的求法,具体实现步骤如下:

(1) 利用 Parzen 窗密度估计法求出包含训练集 X 的最小超球的球心 O , 并将位于该球面上的样本点集合记为 X_{Sph} , 这些样本点的下标集记为 L_{Sph} , 再求出 X 中的点到球心的距离的降序排列集合, 其下标集记为 L_{Sphort} ;

(2)令初始的可能为极点的集合为球面上的点,即 $V_0 = X_{Sph}$,极点的初始集合为空集,即 $V = \emptyset$,极点集合 V 的下标集为 L_v ,则其初始下标集显然为空集,即 $L_v = \emptyset$ 。从 L_{Sphort} 中去除掉初始的可能的极点集合的下标,记为 L^* ,则 $L^* = L_{Sphort} - L_{Sph}$;

(3)通过迭代的方法从 L^* 找出可能的极点集合的下标集 L_{Sph} :取 $i \in L^*$,更新 $L^* = L^* - \{i\}$;如果 $\varphi(x_i)$ 不是 V_0 的内点,即 $F(\varphi(x), V_0) = \text{false}$,则将其下标 i 加入到可能的极点集合的下标集中,即 $L_{Sph} = L_{Sph} \cup \{i\}$,重复该过程直到 $L^* = \emptyset$;

(4)再从步骤(3)求出的可能的极点集合 V_0 的下标集 L_{Sph} 中逐步去掉一些多余的内点的下标,从而求出凸壳的极点集合(即壳向量集合)的下标集 L_v :取 $j \in L_{Sph}$,如果 $\varphi(x_j)$ 不是 $V_0 - \{\varphi(x_i)\}$ 的内点,即 $F(\varphi(x_j), V_0 - \varphi(x_j)) = \text{false}$,也就是说若 $\varphi(x_j)$ 是 $V_0 - \varphi(x_j)$ 的极点,则将其下标 j 加入到极点集合的下标集中,即 $L_v = L_v \cup \{j\}$,重复该过程直到 $L_{Sph} = \emptyset$ 。则 L_v 即为最终求得的壳向量的下标集,从而可记壳向量的集合为 $V = \{\varphi(x_i), i \in L_v\}$ 。

需要说明的是第(3),(4)步都要判断一个点 $\varphi(x)$ 是否为一个集合 V 所确定的凸壳的内点。如果一个点能精确表达成这个集合中的点的凸组合,则这个点就是这个集合的内点, $|V|$ 表示集合 V 中样本点的个数,现在建立一个二次规划问题:

$$\min_{\lambda_i, i=1,2,\dots,|V|} f(\varphi(x), \lambda_i) = (\varphi(x) - \sum_{i=1}^{|V|} \lambda_i \varphi(x_i))^2 \quad (5)$$

$$\text{s. t. } \sum_{i=1}^{|V|} \lambda_i = 1, \lambda_i \geq 0, x_i \in V$$

将式(5)写成内积的形式,则有:

$$\min f(\varphi(x), \Lambda) = k(x, x) + \Lambda^T Q \Lambda - 2 \sum_{i=1}^{|V|} \lambda_i k(x, x_i) \quad (6)$$

$$\text{s. t. } \sum_{i=1}^{|V|} \lambda_i = 1, \lambda_i \geq 0, x_i \in V$$

式中, $\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_{|V|})$; $Q_{ij} = k(x_i, x_j)$ 。若 $\varphi(x)$ 是集合 V 的内点,则 $\varphi(x)$ 能表达成 V 中的点的凸组合,从而上述优化问题中目标函数 $f(\varphi(x), \lambda) = 0$,若 $f(\varphi(x), \lambda) > 0$,则 $\varphi(x)$ 就在集合 V 的外部。

3 算法的设计及实验分析

3.1 算法的设计

通常情况下基于支持向量机的标准增量学习问题可以这样简单描述:存在历史样本集 A 和新增样本集 I ,且满足 $A \cap I = \emptyset$,记 SV^0 和 f^0 分别为历史样本集 A 的支持向量集和决策函数;最终需要寻找得到 $A \cup I$ 上的支持向量集 SV^1 和决策函数 f^1 。本文在研究此算法的基础上,提出了基于壳向量的增量算法,具体描述如下:

新增样本为 I ,设定其拉格朗日乘子 $\alpha = 0$,根据决策函数 f^{t-1} 的 KKT 条件对新增样本进行判断,违反该 KKT 条件的新增样本可以被分为 3 类:

- (1)满足 $0 \leq y_n f(x_n) < 1$ 的样本被正确分类,处于分类间隔中本类点一侧;
- (2)满足 $-1 \leq y_n f(x_n) < 0$ 的样本被错误分类,处于分类间隔中异类点一侧;
- (3)满足 $y_n f(x_n) < -1$ 的样本被错误分类,处于分类间隔外异类点一侧。

记 I_t^v 是新增样本集 I_t 中违反 KKT 条件的样本集。对 $T = SV^{t-1} \cup I_t^v$ 进行增量训练,得到新的决策函数 f^t 和新的支持向量集 SV^t 。

算法如下:

- (1)选择历史样本集 A 和新增样本集 I_t ,计算 A 中两类样本各自的类中心及壳向量 V ,训练 B 得到初始支持向量集 SV^0 和决策函数 f^0 ;
- (2)如果, $I_t \neq \emptyset$,算法终止;否则转(3);
- (3)寻找 I_t 中违反决策函数 f^{t-1} 的 KKT 条件的样本,确定集合 I_t^v ;
- (4)如果 $I_t^v = \emptyset$,置 $SV^t = SV^{t-1}$, $f^t = f^{t-1}$, $t = t + 1$,转(2);否则转(5);
- (5)对 $T = SV^{t-1} \cup I_t^v$ 进行增量学习,得到新的决策函数 f^t 和支持向量集 SV^t ,置 $t = t + 1$,转(2)。

3.2 实验结果与分析

为验证本文方法的有效性,对其行了一系列的实验。实验结果显示,本文方法在保证学习机器具有良好推广能力的同时,不仅学习快,而且可以进行增量学习。所有试验都在软件为 MATLAB7.0、硬件为 Pentium 4/1GB 内存的环境中进行。

3.2.1 不同核函数类型对结果的影响

分别采用 RBF、Linear、Ploy 核函数训练 SVM,对 UCI 数据库中的数据集中进行分类实验。实验时,利用数据集中大约 1/3 的样本进行训练,其余样本用来对 SVM 分类器进行分类性能测试,测试结果如表 1 所列。

表 1 不同核函数时的分类结果

数据	RBF	Linear	Poly
Breast-cancer	0.9775	0.9756	0.9775
Ionosphere	0.9724	0.9061	0.9171
Iris	0.9833	0.9667	0.9750
Wine	0.9392	0.8716	0.8716
Zoo	0.9348	0.9348	0.9348

试验结果显示,核函数的类型对 SVM 分类性能有一定影响;总体来看,选择 RBF 核函数训练得到的 SVM 往往能取得较好的泛化能力和分类性能。

3.2.2 提取壳向量样本对训练速度的影响

采用了 UCI 数据库中的部分数据集进行实验,以验证通过提取壳向量便可提高算法的速度,实验中采用径向基核函数。

表 2 得出了实验结果,表中的符号含义如下: t_{all} 代表所有训练样本的训练时间, t_{ke} 代表壳向量的训练时间, t_{test} 代表测试时间, N_{ke} 代表边界向量数, N_{sv} 代表支持向量数。

表 2 UCI 数据库提取壳向量的实验结果

数据	t_{all}	N_{ke}	t_{ke}	N_{sv}	t_{test}
Iris	1.03	30	1.02	18	0.11
Wine	2.10	79	1.48	27	0.5
Glass	49.28	178	43.21	120	1.03
Letter	9253.40	13725	7298	10152	728.07

3.2.3 本文增量学习算法(OCHULLSVM)与其他增量学习算法比较

在经典的优化算法中,SMO 算法^[18]的性能较好,文献[11]提出的方法在提高学习速度上有很好的代表性,所以本文分别利用 3 种算法对 UCI 标准数据库中的 Breast-cancer

数据集与在某电路板上采集的故障数据集进行对比实验。

(1) Breast-cancer 数据集, 共有 699 个样本, 样本维数为 11, 所用训练样本数为 370, 测试样本数为 329。

(2) 某电路板上的故障数据中的每一分量都服从 Gauss 分布, 共有 800 个样本, 取训练样本为 450, 测试样本数为 350, 其中正例样本维数为 7, 样本类别数为 4。

为确保实验结果的精确性, 实验采用平均法, 在同样条件下运行 10 次, 取平均值作为测试结果。实验中时间均以秒(s)为单位, 分类精度以%为单位。采用径向基核函数, $C=10, \gamma=0.4$ 。

表 3 和表 4 给出了实验结果, 表中的符号含义如下: $N_{\text{初始}}$ 代表初始样本个数, $N_{\text{增量}}$ 代表增量样本个数, $t_{\text{训练}}$ 代表训练时间, ACR 代表平均分类正确率, OCHULLSVM 代表本文的增量算法, SMO 代表文献[18]中的增量算法, HC-SVM 代表文献[11]中的增量算法。

表 3 Breast-cancer 数据集实验结果

N 初始	N 增量	OCHULLSVM		SMO		HC-SVM	
		$t_{\text{训练}}$	ACR	$t_{\text{训练}}$	ACR	$t_{\text{训练}}$	ACR
100	50	1.87	97.5	2.40	97.5	1.86	97.1
50	100	1.89	98.0	4.03	98.2	1.86	96.9
110	80	2.15	97.7	4.26	97.5	2.10	97.3
110	100	2.28	96.5	4.50	97.0	2.23	94.6
120	40	2.38	98.2	3.66	98.2	2.40	96.1
130	90	2.70	98.0	4.95	97.7	2.68	97.3

表 4 电路板故障数据集实验结果

N 初始	N 增量	OCHULLSVM		SMO		HC-SVM	
		$t_{\text{训练}}$	ACR	$t_{\text{训练}}$	ACR	$t_{\text{训练}}$	ACR
50	100	11.06	96.8	26.7	96.8	11.10	96.6
150	100	30.1	97.6	57.6	97.4	28.4	97.0
200	50	10.9	97.8	23.0	96.0	9.8	96.1
200	200	14.0	96.6	34.3	97.0	10.2	95.4
400	100	24.3	94.8	42.9	96.1	22.7	94.3
300	200	22.84	97.8	44.5	97.1	21.6	21.35

从上面实验可以看出: 与 SMO 相比, 本文的 OCHULLSVM 不仅能保证学习机器具有较高的精度, 而且学习速度有显著的提高, 这是由于在每一轮的增量训练中, 新训练样本集主要由包含原所有支持向量的壳向量和新样本中违背 KKT 条件的样本构成, 这样新的训练样本集既保留了历史所有的分类信息, 也淘汰了大量历史无用样本约简训练集, 从而在保证分类精度的同时提高了学习机的学习速度。与 HC-SVM 相比, 本文的 OCHULLSVM 在学习速度上虽然略具劣势, 但在分类精度上具有明显的优势, 这是由于在每轮的增量学习中, HC-SVM 可以通过确定阈值提取出类边界壳向量, 类边界壳向量将作为新的训练样本集参与下一次的训练, 这样大大简约了训练样本集的规模, 节省了时间, 但在阈值的确定不准确的情况下易导致丢失部分重要历史信息, 造成分类精度下降。

结束语 本文基于支持向量机的特性, 研究了支持向量机的增量学习方法, 并在此基础上提出了基于 KKT 条件及壳向量的增量学习算法。该算法在每一轮当前增量训练的训练样本集中, 有效保留了含有重要分类信息的历史训练样本, 并对当前增量训练的训练样本集进行了约简, 保留了最有可

能成为支持向量的训练样本集进行 SVM 增量训练。实验结果表明, 该算法不仅能保证学习机器的精度和良好的推广能力, 而且其学习速度比经典的 SVM 算法快, 可以进行增量学习。

参考文献

- [1] Vapnik V. The nature of statistical learning theory [M]. New York: Springer Press, 1995
- [2] Zhu H B, Cai Y. Text categorization based on active learning support vector machines [J]. Computer Engineering and Application, 2009, 45(2): 134-136
- [3] Mu Xin-guo, Hao Wen-ning, Zhao En-lai. An incremental LS-SVM learning algorithm IL-SVM [C] // 2011 International Conference on E-Business and E-Government (ICEE). 2011: 314-317
- [4] Syed N A, Liu H, Sung K K. Incremental learning with support vector machines [C] // Proc Int Joint Conf on Artificial Intelligence, 1999
- [5] 申晓勇, 雷英杰. 一种 SVM 增量学习淘汰算法 [J]. 计算机工程与应用, 2007, 43(6): 171-173
- [6] 徐海龙, 王晓丹, 史朝辉, 等. 一种基于距离比值的支持向量机增量训练算法 [J]. 空军工程大学学报, 2008, 9(4): 29-33
- [7] 李祥纳, 艾青, 秦玉平, 等. 支持向量机增量学习算法综述 [J]. 渤海大学学报, 2007, 9(4): 187-189
- [8] Salyer B, Tyson R C, Sergiu M. Recursive, hyperspherical behavioral learning for robotic control [C] // 2010 World Automation Congress, 2010
- [9] 白冬婴, 王晓丹, 马飞. 支持向量机增量学习方法及应用 [J]. 航空计算技术, 2007, 37(4): 23-26
- [10] 覃俊, 许斐. 基于壳向量的支持向量机渐进式增量学习算法 [J]. 中南民族大学学报: 自然科学版, 2012, 30(3): 94-97
- [11] 吴崇明, 王晓丹, 白冬婴, 等. 基于类边界壳向量的快速 SVM 增量学习算法 [J]. 计算机工程与应用, 2010, 46(23): 185-187, 248
- [12] 李东晖, 杜树新, 吴铁军. 基于壳向量的线性支持向量机快速增量学习算法 [J]. 浙江大学学报: 工学版, 2006, 40(2): 202-206, 215
- [13] 郭鹏, 孙晓梅, 薛明. 基于壳向量的边界邻近支持向量机 [J]. 黑龙江交通科技, 2008, 31(12): 169-170
- [14] Yu Ren, Mei Sheng-xin. A SVM incremental learning algorithm based on hull vectors and center vectors [C] // 2010 Sixth International Conference on Natural Computation, 2010
- [15] 周伟达, 张莉, 焦李成. 支撑向量机推广能力分析 [J]. 电子学报, 2001, 29(5): 590-594
- [16] 薛贞霞. 支持向量机及半监督学习中若干问题的研究 [D]. 西安: 西安电子科技大学, 2009
- [17] Keerthi S S, Shevade S K, Bhattacharyya C, et al. A fast iterative nearest point algorithm for support vector machine classifier design [J]. IEEE Transaction on Neural Network, 2000, 11(1): 124-136
- [18] Platt J. Fast Training of Support Vector Machines Using Sequential Minimal Optimization [A] // Advances in Kernel Methods-Support Vector Learning [C]. Cambridge, MA: MIT Press, 1999: 185-208