

一种广义不可分的支持向量机算法

邹永祥^{1,2} 吴宗亮^{1,2}

(1. 宜宾学院计算机科学与技术研究所, 宜宾, 644000; 2. 电子科技大学电子工程学院, 成都, 610054)

摘要: 针对标准的 C-SVM(C-support vector machine) 算法在处理很多实际分类问题时, 对识别错误代价损失差异很大的极端情况表现出的局限性, 提出一种通用的广义支持向量机算法。根据识别错误后所付出的代价, 可以把最优分类面向代价损失低的一方进行推移, 留给代价损失高的一方更大的空间, 提高其识别率, 从而减小识别错误后带来的代价损失。该方法进一步提高了标准 C-SVM 的适用性以及样本的正确识别率, 将新算法应用到高分辨雷达距离像的识别中, 实验证明, 广义 C-SVM 能取得比传统 C-SVM 更好的识别效果。

关键词: 广义支持向量机; 最优分类面; 识别错误; 高分辨雷达距离像

中图分类号: TP391.4 **文献标志码:** A

Generalized C-Support Vector Machine Algorithm

Zou Yongxiang^{1,2}, Wu Zongliang^{1,2}

(1. Institute for Computer Science & Technology, Yibin University, Yibin, 644000, China; 2. College of Electronic Engineering, University of Electronic Science and Technology of China, Chengdu, 610054, China)

Abstract: Standard C-support vector machine (C-SVM) algorithm has certain limitation when dealing with many factual pattern classification problems, especially in the extreme case such as the recognition error cost loss in great difference. A kind of generalized C-SVM algorithm is introduced. By estimating the cost of the recognition error, optimal separating hyperplane can be translated into the low cost passage, and leaves more space for the high lost cost to increase recognition rate, thus reducing the damage of recognition error. The new method improves the applicability of C-SVM and sample recognition correct rate. When applied to radar high resolution range profile's recognition, experimental results show that the proposed method can achieve better recognition effect than the traditional method.

Key words: generalized C-support vector machine; optimal separating hyperplane; recognition error; radar high resolution range profile

引 言

支持向量机^[1](Support vector machine, SVM)是从线性可分情况下提出, 要求其最优分类面不但能将两类正确分开(训练错误率为 0)^[2], 而且使分类间隔最大。但在线性不可分情况下, 这种分类面不存在。标准的支持向量机 C-SVM^[3]为解决不可分问题, 引入惩罚系数 C 作为分类间隔和训练集被错划

的程度这两个目标之间的权重,从而得到平分最近点和最大间隔之间的折衷。这种方法得到的分类面依赖于样本点和 C ,当 C 取值较小时,很可能出现当所有训练样本划分为一类的极端情况,这显然不合理。为解决此问题,本文在标准 C-SVM 的数学模型基础上,提出一种基于不等距最优分类面的广义 C-SVM 算法,通过对传统 C-SVM 中求得的分类面进行适当修正,以期达到最佳的识别效果。

1 C-SVM 算法

1.1 C-SVM 算法简介

标准的 C-SVM 算法^[4]是样本点线性不可分情况下引入的软间隔支持向量机。在非线性分类问题中,对于给定的数据样本集为 (x_i, y_i) ^[5],其中 $i=1, 2, \dots, l, x_i \in \mathbf{R}^n$ 且令其为 n 维样本空间列向量, $y_i \in \{+1, -1\}$ 是样本 x_i 所属类的类别标识。标准的 C-SVM 算法一方面通过引进松弛变量 ζ 放松约束,另一方面引进从输入空间 \mathbf{R}^n 到 Hilbert 空间 H 的变换

$$\Phi: X \subset \mathbf{R}^n \rightarrow H \quad x \rightarrow \Phi(x) \tag{1}$$

把训练集 $T = \{(x_1, y_1), \dots, (x_l, y_l)\}$ 映射为 $\bar{T} = \{(\Phi(x_1), y_1), \dots, (\Phi(x_l), y_l)\}$,该映射将 x 从输入空间 X 映射到一高维的特征空间 H 。正确对训练数据分类是指求得的最优分类超平面,不但要把两类样本点无错误地分开,而且要使分类空隙最大^[6],因此最优分类面的求解问题可归结为如下的优化问题

$$\begin{cases} \min_{\mathbf{w}, \xi} \rho(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C(\sum_{i=1}^l \xi_i) & (2) \\ \text{s. t.} \quad y_i[\mathbf{w}^\top \Phi(x_i) + b] - 1 + \xi_i \geq 0, \xi_i \geq 0, i=1, 2, \dots, l & (3) \end{cases}$$

式中: \mathbf{w} 是超平面的法向量, b 是超平面偏值,惩罚分量 $C > 0$ 是一个常数,它控制对错误分类的惩罚程度, C 越大表示对错误分类的惩罚越大,它是算法中唯一可以调节的参数。一般情况下,把基于不可分样本集的支持向量机称之为标准 C-SVM。如果每个松弛项 $\xi_i (i=1, \dots, l)$ 都等于 0,此时不可分样本集也就退化成了可分样本集,所以可分样本集只是不可分样本集的一个特例。C-SVM 算法在处理不可分样本集的模式分类问题时具有良好的性能。

1.2 标准 C-SVM 算法的不足

在标准 C-SVM 算法中,最优分类面是使分类面到正负两类之间的分类^[7]间隔相等,这样可以使得结构风险最小化,正负两类都平等地获得两类之间的区域。如果有正负两类样本集合,采用 C-SVM 算法进行识别,可能出现有一类的识别率比较高,而另一类的识别率相对较低,为了使得正负两类都获得较高的识别率,此时可以将最优分类面向识别率较高的一方进行适当地推移,给识别率较低的一方留下较大的空间,从而达到在不降低一类识别率的基础上提高另外一类识别率的目的。因此需要对现有的 C-SVM 算法进行改进,以进一步提高其推广性能。

2 广义 C-SVM 算法的推导过程

2.1 广义 C-SVM 公式推导

标准支持向量机的最优分类面到正负两类的间隔都是 $1/\|\mathbf{w}\|$,如图 1(a)所示。为了解决上面所提出的分类问题,引入不等距最优分类超平面^[8],如图 1(b)所示。以线性不可分的情况为例,对在高维特征空间中的不等距最优分类面的广义 C-SVM 算法进行推导。如图 1(a),令最优分类面到正、负样本集合的距离分别为 $\lambda/\|\mathbf{w}\|$ 和 $1/\|\mathbf{w}\|$, λ 是为调节最优分类面与正负两类之间的距离而引入的参数,此时正负两类之间的分类间隔为

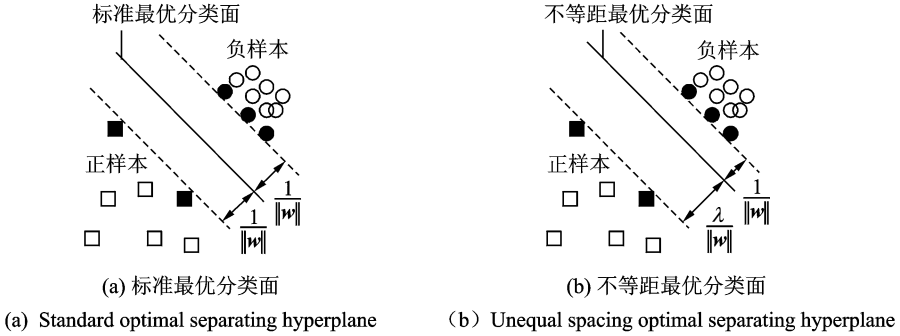


图 1 两种最优分类面

Fig. 1 Two kinds of optimal separating hyperplane

$$\frac{\lambda}{\|\mathbf{w}\|} + \frac{1}{\|\mathbf{w}\|} = \frac{1+\lambda}{\|\mathbf{w}\|} \quad (4)$$

此时,对于线性不可分的情况,需要优化的目标函数为

$$\min_{\mathbf{w}, \xi} \rho(\mathbf{w}, \xi) = \frac{1}{1+\lambda} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (5)$$

相应地,约束条件为

$$\begin{cases} y_i[\mathbf{w}^T \Phi(\mathbf{x}_i) + b] - \lambda + \xi_i \geq 0 & y_i = 1 \\ y_i[\mathbf{w}^T \Phi(\mathbf{x}_i) + b] - 1 + \xi_i \geq 0 & y_i = -1 \\ \xi_i \geq 0 & i = 1, 2, \dots, l \end{cases} \quad (6)$$

$$(7)$$

$$(8)$$

式中: $\lambda > 0$,是根据样本集确定的常数,目的在于控制分类超平面与正负两类之间的间隔比例。当 $0 < \lambda < 1$ 时,分类超平面靠近正样本类;当 $\lambda > 1$ 时,分类超平面靠近负样本类;当 $\lambda = 1$ 时,即为标准的分类超平面。

为求解式(5)的目标函数 ρ 在约束条件(即式(6~8))下的最小值,构造如下 Lagrange 函数^[9] L

$$\begin{aligned} \min_{\mathbf{w}, b, \xi} L(\mathbf{w}, b, \xi, \boldsymbol{\alpha}, \boldsymbol{\beta}) &= \rho(\mathbf{w}, \xi) - \left\{ \sum_{y_i=1} \alpha_i [y_i(\mathbf{w}^T \Phi(\mathbf{x}_i) + b) - \lambda + \xi_i] + \sum_{y_i=-1} \alpha_i [y_i(\mathbf{w}^T \Phi(\mathbf{x}_i) + b) - 1 + \xi_i] \right\} - \\ & \sum_{i=1}^l \beta_i \xi_i = \rho(\mathbf{w}, \xi) - \sum_{i=1}^l \alpha_i [y_i(\mathbf{w}^T \Phi(\mathbf{x}_i) + b) + \xi_i] - \sum_{i=1}^l \beta_i \xi_i + \lambda \sum_{y_i=1} \alpha_i + \sum_{y_i=-1} \alpha_i \\ \text{s. t. } & \alpha_i \geq 0, \beta_i \geq 0, i = 1, 2, \dots, l \end{aligned} \quad (9)$$

式中: α_i 和 β_i 为 Lagrange 乘子系数。现将式(9)首先对 b 求偏导,并令其偏导数等于0,可得

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^l y_i \alpha_i = 0 \Rightarrow \sum_{y_i=1} \alpha_i = \sum_{y_i=-1} \alpha_i = \frac{1}{2} \sum_{i=1}^l \alpha_i \quad (10)$$

把式(10)代入式(9)中,得到

$$\min_{\mathbf{w}, b, \xi} L(\mathbf{w}, b, \xi, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \rho(\mathbf{w}, \xi) - \sum_{i=1}^l \alpha_i [y_i(\mathbf{w}^T \Phi(\mathbf{x}_i) + b) + \xi_i] - \sum_{i=1}^l \beta_i \xi_i + \frac{1+\lambda}{2} \sum_{i=1}^l \alpha_i \quad (11)$$

将式(11)分别对 \mathbf{w} , ξ_i 求偏导,并令偏导数等于0,可得

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \frac{1+\lambda}{2} \sum_{i=1}^l y_i \alpha_i \Phi(\mathbf{x}_i) \quad (12)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow \beta_i = C - \alpha_i \quad (13)$$

将式(12,13)代入(11),并考虑到式(10),可得如下形式的对偶优化问题

$$\begin{aligned} \max_{\alpha} W(\alpha) &= \frac{1+\lambda}{2} \left\{ \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \right\} \\ \text{s. t.} \quad & \sum_{i=1}^l y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C, i=1, 2, \dots, l \end{aligned} \quad (14)$$

其中 $k(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ 。

由此可知,式(14)中最优参数 Lagrange 乘子向量 \mathbf{a}^* 与标准 C-SVM 求解相同,因此可以采用标准的支持向量机训练算法求得向量 \mathbf{a}^* ,在此基础上,由式(12)可得到高维空间中线性不可分情况下不等距最优分类面的法向量为

$$\mathbf{w}^* = \frac{1+\lambda}{2} \sum_{i=1}^l y_i \alpha_i^* \Phi(\mathbf{x}_i) \quad (15)$$

根据 KKT(Karush-Kuhn-Tucker) 条件定理^[10],可以得到求解 b^*

$$\begin{cases} b^* = \lambda - (\mathbf{w}^*)^T \Phi(\mathbf{x}_i) & 0 < \alpha_i^* < C, y_i = 1 \\ b^* = -1 - (\mathbf{w}^*)^T \Phi(\mathbf{x}_i) & 0 < \alpha_i^* < C, y_i = -1 \end{cases} \quad (16)$$

$$\quad (17)$$

最后,可以得到如下形式的分类判别函数

$$g(\mathbf{x}) = \text{sgn} \left[\frac{1+\lambda}{2} \sum_{i=1}^l y_i \alpha_i^* k(\mathbf{x}_i, \mathbf{x}) + b^* \right] \quad (18)$$

当 $\lambda=1$ 时,上述算法就退化成了标准 C-SVM 算法,把基于不等距最优分类面的 C-SVM 算法称为广义 C-SVM 算法,它是 C-SVM 算法的一种合理推广。可以采用标准的 C-SVM 算法对广义 C-SVM 算法进行训练。

2.2 广义 C-SVM 的讨论

2.2.1 参数 λ 的选取

在广义 C-SVM 算法中, λ 是一个关键参数,它的初始值的确定很重要。 λ 的初始值设定有多种方法,例如根据类内离散度来确定 λ 的初始值,不过这些方法都比较复杂,下面给出一种更简捷,更容易计算 λ 初始值的方法。

(1) 在高维特征空间中,对于给定的数据样本集,令正类训练样本集合为 $\{\Phi(\mathbf{x}_i)\} (i=1, 2, \dots, l_1)$,那么其中心点^[11]为

$$\Phi_s = \frac{1}{l_1} \sum_{i=1}^{l_1} \Phi(\mathbf{x}_i) \quad (19)$$

那么正样本集合的一个点到其中心点的期望平方距离 d_1 可以表示为

$$d_1 = \frac{1}{l_1} \sum_{s=1}^{l_1} \|\Phi(\mathbf{x}_s) - \Phi_s\|^2 = \frac{1}{l_1} \sum_{s=1}^{l_1} k(\mathbf{x}_s, \mathbf{x}_s) - \frac{1}{l_1^2} \sum_{i,j=1}^{l_1} k(\mathbf{x}_i, \mathbf{x}_j) \quad (20)$$

令 $\Psi = \{\Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_{l_1})\}$,则 $\mathbf{K} = \Psi^T \Psi$, \mathbf{K} 是核矩阵。所以 d_1 本质上是核矩阵对角线元素的平均值减去所有元素的平均值。 d_1 越大,正样本集合越分散, d_1 越小,正样本集合越集中。对于负类训练样本集合,其集合中的一个点到其中心点的期望平方距离 d_2 的计算方式同上。根据计算出的 d_1, d_2 ,此时 λ 的初始值可以设定 d_1/d_2 的值或其值的算术平方根。初始值确定后,就可代入广义 C-SVM 进行训练,就可得到对样本有高识别率的向量机。

(2) 具体应用中对 λ 值的调整。实践中在具体分类识别时,根据训练样本集合由上述方法确定的 λ 初始值可能不是最优的,此时可对 λ 值进行微调,以期达到更好的识别效果。对 λ 值的调整可依据以下两个原则:

① 从理论上,正负类两类的平均识别率最高时的 λ 值最佳。令正类的识别率为 $\eta_+(\lambda)$,负类的识别率为 $\eta_-(\lambda)$,当平均识别率 $(\eta_+(\lambda) + \eta_-(\lambda))/2$ 为最大时的 λ 值,即所要求的最佳的 λ 值。

②识别错误损失最小原则。假设正类和负类样本的识别错误时代价损失分别为 δ_+ 和 δ_- , 此时可以把广义 C-SVM 算法中的参数 λ 调整为 $\lambda = \delta_+ / \delta_-$, 此时最优分类面将向代价损失低的一方进行推移, 留给识别错误时代价损失高的一方更大的空间, 以减少损失。

2.2.2 广义 C-SVM 算法应用于多类目标识别

当要区分的类别多于两类时, 已有许多算法将 SVM 推广到多类问题^[12], 大致分为两大类: (1) 通过某种方式构造一系列的两类 SVM, 并将它们组合在一起实现多类分类; (2) 将多个分类面的参数求解合并到一个最优化问题中, 通过求解该最优化问题实现多类分类。第(2)类方法在求解最优化问题过程中的变量远远多于第一类方法, 训练速度、分类速度慢, 并且预测精度也不占优。这里采用第一类方法, 通过建立多个 SVM 分类器的方式加以解决。在较少的训练和测试时间下“One-against-one”方法可获得更高的正确识别率。假设有 g 个类别, 则为每两类都建立一个 SVM, 如此共有 $g(g-1)/2$ 个 SVM, 然后再采用投票的方式进行分类, 对于测试的样本, 使之通过所有 SVM 分类器, 最后得票最多的类即为所要确定的样本类别。因此在广义 C-SVM 应用于多类目标识别时, SVM 在两类情况下识别率如果提高, 那么在多类情况下的识别效果自然就会提高。

3 实验分析

3.1 实验设置

本文实验所采取的实测数据是逆合成孔径雷达对空中的 2 种飞机 (a, b) 所成的距离像^[13], 实验数据为 2 种飞机各取一段的 130 幅距离像 (总数为 260 幅) 作训练样本, 另外 130 幅为测试样本 (总数为 260 幅)。在对实测数据训练前, 作如下两步预处理: (1) 归一化。将每一幅像用其总能量归一。(2) 距离对准。利用傅里叶变换的平移不变性, 将目标一维距离像作傅里叶变换即可对齐, 同时根据实数傅里叶变换的共轭对称性, 取一维距离像傅里叶变换的一半 (128 维) 作为识别输入矢量进行实验。在实验中, 参数设置为 $r=100$; 高斯径向基核函数的参数 $\sigma^2=0.2$ 。

3.2 算法性能分析

实验 1 以上述 a 和 b 两组数据为实验数据。把每种飞机所选段的所有 260 幅一维距离像全部作为实验数据, 按间隔取一的方式划分为训练样本集和测试样本集, 那么每一组实验数据所构成的总训练样本集中有 260 个训练样本, 每类各 130 个训练样本, 总测试样本集样本数同总训练样本集。采取广义 C-SVM 算法分别对组实验数据进行分类识别, 实验结果如表 1 所示。在表 1 中, 以 a 型飞机为正类, b 型飞机为负类。

表 1 a 型和 b 型飞机的广义 C-SVM 实验结果

Table 1 Generalized C-SVM experiment results of plane type a and b

序号	λ 的取值	a 型识别率/%	b 型识别率/%	平均识别率/%
1	1.00	91.54	97.69	94.62
2	1.20	92.31	96.92	94.62
3	1.25	93.08	96.92	95.00
4	1.30	93.85	96.92	95.38
5	1.33	93.85	96.92	95.38
6	1.44	94.62	96.92	95.77
7	1.45	94.62	96.15	95.38

实验结果分析如下:

(1) 采用标准 C-SVM 算法时, a 型和 b 型飞机的平均识别率分别为 89.67% 和 93.33%, 与表 1 中数

据相比,广义 C-SVM 算法确实可以取得更好的识别效果。在表 1 中随着 λ 的增大,b 型飞机的识别率有所下滑,但是 a 型飞机识别率的增长速度更快,所以平均识别率在上升,况且 b 型飞机识别率的下滑并不明显(如表 1 中第 1 号至第 6 号数据)。

(2)广义 C-SVM 中最佳识别效果的 λ 取值。在表 1 中,设 a 型飞机为正类, b 型飞机为负类;当 $\lambda=1.00$ 时,正类的识别率要低于负类的识别率,把最优分类面向负类一方移动,即让 $\lambda>1$,留给正类更大的空间。表 1 中当 $\lambda=1.44$ 时,可取得最佳的识别效果,若 λ 进一步增大,负类的识别率就要明显下降。此外,利用式(20)分别计算出 d_1 和 d_2 ,可以发现 $d_1>d_2$,所以正类的分布要较负类分散一些,在这种情况下,可把 λ 的初始值设置为 d_1/d_2 的值,通过计算得 $d_1/d_2=1.33$,可以看出,在表 1 中 $\lambda=1.33$ 时的识别效果已经和最佳的识别效果很接近,从而验证了上文所给出的 λ 初始值设定的合理性。

由实验分析,合适的 λ 取值可取得最佳的识别效果。此时,可对 λ 的初始值进行微调,即正类的识别率为 $\eta_+(\lambda)$,负类的识别率为 $\eta_-(\lambda)$ 时,采用平均识别率 $(\eta_+(\lambda)+\eta_-(\lambda))/2$ 为最大时的 λ 值,即可得最佳的 λ 值,同时需确保某一类的正确识别率不明显下滑。

(3)采用广义 C-SVM 算法对识别错误代价损失差异很大的 δ 极端情况分析。令 a 型和 b 型飞机的代价损失分别为 δ_a 和 δ_b ,此时可以把广义 C-SVM 算法中的参数 λ 设置为 $\lambda=\delta_a/\delta_b$,由于 $\delta_a>\delta_b$,所以 $\lambda>1$,故可以给 a 型飞机一方留下更大的空间,以提高其识别率。如果把最优分类面朝着 b 型一方持续不断地进行推移,那么留给 a 型飞机的空间将会越来越大,a 型飞机的识别率也会越来越高,虽然这以损失 b 型飞机的识别率为代价,不过这将有利于解决 a,b 两类型飞机代价损失差异很大这种极端情况。

实验 2 训练样本集和测试样本集的划分同实验 1。假设 a 型飞机识别错误以后带来的代价损失大于 b 型飞机,以 a 型飞机为正类,b 型飞机为负类,采取广义 C-SVM 算法进行识别,实验结果如表 2 所示。

表 2 不同代价损失情况下两类飞机的识别结果

Table 2 Recognition results in case different cost loss for two types of aircraft

序号	λ 的取值	a 型识别率/%	b 型识别率/%	平均识别率/%
1	1.50	95.38	96.15	95.77
2	1.95	96.15	95.38	95.77
3	2.00	96.92	95.38	96.15

在表 2 中,把分类超平面朝着代价损失低的 b 型飞机一方持续推移,目的是给代价损失高的 a 型飞机一方留下更大的空间,以提高 a 型飞机的识别率。观察表 2 可以看出,当 λ 的取值持续增大时,a 型飞机的识别率上升,而 b 型飞机的识别率下降,当 $\lambda=2.00$ 时,a 型飞机可以取得很高的识别率。把表 2 的第 3 号实验结果和表 1 的第 1 号实验结果进行比较可以看出,代价损失低的 b 型飞机的识别率虽然下降了 2.31%,但是其仍旧保持了比较高的识别率,从而验证了利用广义 C-SVM 算法解决不同代价损失情况下雷达目标识别的有效性。

4 结束语

本文针对标准 C-SVM 的不足之处,提出了广义 C-SVM 算法,并对其进行了详尽的阐述,实验结果证明了本文所采取的算法在处理高分辨雷达距离像的优越性,并且该方法也可以应用到计算机图像识别或雷达图像处理、信号处理、基因图谱识别和故障诊断以及其他模式识别等领域。

参考文献:

[1] Vapnik V N. Statistical learning theory[M]. New York: Wiley, 1998.
 [2] 边肇祺,张学工. 模式识别[M]. 2 版. 北京:清华大学出版社,2000:296-301.

Bian Zhaoqi, Zhang Xuegong. Pattern recognition[M]. 2nd Ed. Beijing: Tsinghua University Press, 2000: 296-301.

- [3] Lin Kengpei, Chen Mingsyan. On the design and analysis of the privacy-preserving SVM classifier[J]. *IEEE Trans on Knowledge and Data Engineering*, 2011, 23(11): 1704-1717.
- [4] Xie Zhipeng. Positive definite kernel in support vector machine[J]. *Transactions of Nanjing University of Aeronautics and Astronautics* 2009, 26(2): 114-121.
- [5] Xu qihua, Geng shuai. A fast SVM classification learning algorithm used to large training set[C]//*Intelligent System Design and Engineering Application (ISDEA)*. Piscataway, NJ: IEEE, 2012: 15-19.
- [6] Hsu C, Lin C. A comparison of methods for multiclass support vector machines[J]. *IEEE Trans on Neural Networks*, 2002, 13(2): 415-425.
- [7] Ben Fei, Liu Jinbai. Binary tree of SVM: A new fast multiclass training and classification algorithm[J]. *IEEE Trans on Neural Networks*, 2006, 17(3): 696-704.
- [8] 唐发明. 基于统计学习理论的支持向量机算法研究[D]. 武汉: 华中科技大学, 2005.
Tang Faming. Research on support vector machine algorithm based on statistical learning theory[D]. Wuhan: Huazhong University of Science and Technology, 2005.
- [9] 崔建国, 李一波, 李忠海, 等. 基于小波包与支持向量机的复杂信号模式识别[J]. *数据采集与处理*, 2008, 23(2): 163-167.
Cui Jianguo, Li Yibo, Li Zhonghai, et al. Complicated signal pattern recognition based on wavelet packet and support vector machine[J]. *Journal of Data Acquisition and Processing*, 2008, 23(2): 163-167.
- [10] Vapnik V N. The nature of statistical learning theory[M]. New York: Spinger-Verlag, 1999.
- [11] 薛贞霞, 刘三阳, 齐小刚. 基于壳向量和中心向量的支持向量机[J]. *数据采集与处理*, 2009, 24(3): 328-334.
Xue Zhenxia, Liu Sanyang, Qi Xiaogang. Support vector machines based on hull vectors and center vectors[J]. *Journal of Data Acquisition and Processing*, 2009, 24(3): 328-334.
- [12] 闫志刚, 杜培军. 多类支持向量机推广性能分析[J]. *数据采集与处理*, 2009, 24(4): 469-475.
Yan Zhigang, Du Peijun. Generalization performance analysis of m-SVMs[J]. *Journal of Data Acquisition and Processing*, 2009, 24(4): 469-475.
- [13] 杜兰. 雷达高分辨距离像目标识别方法研究[D]. 西安: 西安电子科技大学, 2007.
Du Lan. Reserch on radar HRRP target recognition[D]. Xi'an: Xi'an Electronic and Engineering University, 2007.

作者简介: 邹永祥(1973-), 男, 副教授, 研究方向: 信号与智能信息处理, E-mail: zyx688953@163.com; 吴宗亮(1979-), 男, 博士研究生, 讲师, 研究方向: 信号处理、雷达目标识别。

