

一种基于遗传算法的 SVM 决策树多分类策略研究

连 可, 黄建国, 王厚军, 龙 兵

(电子科技大学自动化工程学院, 四川成都, 610054)

摘 要: 提出了一种基于遗传算法(GA)的 SVM 最优决策树生成算法,并将其应用于解决 SVM 多分类问题. 首先以最大分类间隔为准则,利用遗传算法对传统的 SVM 决策树进行优化,生成最优(或近优)决策二叉树;然后在各个决策节点,利用传统的 SVM 算法进行二值分类,最终实现 SVM 的多值分类. 理论分析及实验结果表明,新方法比传统的 DT-SVM、DAG-SVM 方法有更高的分类精度,比经典的 1-a-1、1-a-r 有更高的训练和分类效率.

关键词: 支持向量机; 遗传算法; 决策树

中图分类号: TP39 **文献标识码:** A **文章编号:** 0372-2112 (2008) 08-1502-06

Study on a GA-based SVM Decision-tree Multi-Classification Strategy

LIAN Ke, HUANG Jian-guo, WANG Hou-jun, LONG Bing

(Department of Automation Engineering, University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China)

Abstract: This paper presents a GA-based decision-tree algorithm to deal with SVM multi-class classification problem. First, GA is used to create optimal or near-optimal decision-tree automatically, which makes the margin between two classes maximal at every decision node. Then at every decision node, standard SVM is used to make binary classification. Finally, the SVM decision tree achieves multi-classification. Theoretical analysis and experiments show that the proposed method is more precise than the traditional "DT-SVM" and "DAG-SVM" methods, and has higher training and testing efficient than classical "1-a-1" and "1-a-r" methods.

Key words: support vector machine; genetic algorithm; decision tree

1 引言

利用支持向量机(SVM)处理多类别分类是 SVM 研究的热点问题之一. 目前已提出的 SVM 多分类方法大致可分为两类:一次性求解法和分解重构法. 一次性求解法是由 Weston 等人在 1998 年最早提出^[1]的,它在所有训练样本上求解一个大型二次规划问题,同时将所有样本分开. 此后,李昆仑等人通过在惩罚项中引入模糊成员函数对 Weston 等人的方法进行了改进,降低了噪声对分类结果的影响^[2]. 但总的来讲,由于该方法变量个数多,计算复杂度高,尤其在类别数目多时,其训练速度低,分类精度也不高,其实用性并不强. 分解重构法是一种将多类分类问题转化为多个两类分类问题,并采用某种策略将多个两类分类器组合起来实现多分类的方法. 实验表明,这是一种比一次性求解法更适合于实际应用的方法^[3]. 目前已提出的方法主要包括:one-against-

rest (1-a-r)^[4]、one-against-one (1-a-1)^[5]、Directed Acyclic Graph SVM (DAG-SVM)^[6]、Decision-tree-based multi-class SVM (DT-SVM)^[7]等. 在上述方法中,1-a-1 采用“一对一”的方法训练基本 SVM,采用投票法组合策略进行多分类. 该方法的优点是分类精度高,但缺点是对于 K 分类问题必须训练 $K(K-1)/2$ 个基本 SVM,且分类必须遍历所有训练的 SVM,训练复杂,分类效率低. 1-a-r 采用“一对其余”的方法训练基本 SVM,采用“最大输出”法实现多分类. 该方法虽然所需训练的基本 SVM 较 1-a-1 大大减少,但是各 SVM 都是在全部训练集样本上进行学习的,当样本数较多时,训练速度很慢. 同时,该方法分类时也必须遍历所有 K 个 SVM,效率也不高. DT-SVM 和 DAG-SVM 采用了决策树的组合分类结构. 在每个决策节点,DT-SVM 采用“一对其余”的训练方法,DAG-SVM 采用“一对一”的训练方法. 由于决策树的引入,所需训练的基本 SVM 大大减少,分类时也不必遍历所有训练

收稿日期:2007-08-29;修回日期:2008-03-06

基金项目:国防基础科研(No. A1420061264);国家自然科学基金(No. 60673011)

的 SVM,训练和分类的效率都明显提高.但是,这两种多分类方法都采用固定的树结构,而且包括根节点在内各个决策节点的选择具有随意性,因而容易产生“误差积累”,分类性能并不稳定,往往达不到最优.

本文提出一种基于遗传算法的 SVM 决策树多分类方法,在决策树的每个决策节点利用遗传算法进行两分类决策优化,最终自动生成最优(或近优)决策树.由于 GA 优化的引入,使得决策树的结构具有自适应性,在保证训练和分类效率的同时,使分类性能达到最优(或近优).理论分析和实验结果表明,新方法比传统的 DT-SVM、DAG-SVM 方法有更高的分类精度,比经典的 1-a-1、1-a-r 有更高的训练和分类效率.

2 支持向量机(SVM)

为了使本文具有自包含性,本节对支持向量机(SVM)的相关理论进行简要介绍. SVM 是从线性可分的二分类问题发展而来的,其基本思想是寻找两类样本的最优分类面,使得两类样本的分类间隔(margin)最大^[8]. 以图 1 所示为例:图中,实心点和空心点分别代表两类样本, H 为分类线, H_1 和 H_2 分别为各类中离分类线最近的样本且平行于分类线的直线,它们之间的距离叫做分类间隔(margin). 所谓最优分类线就是要求分类线不但能将两类正确分开,而且使分类间隔最大.




图 1 SVM 二分类问题

不失一般性,设训练样本 $(x_i, y_i), i = 1, 2, \dots, l, x \in R^n, y \in \{+1, -1\}, l$ 为样本数, n 为输入维数. 在线性可分的情况下将两类样本完全分开的超平面为:

$$w \cdot x + b = 0 \quad (1)$$

使分类间隔最大的超平面即为最优分类面,为此,需要求解二次规划问题:

$$\begin{aligned} \min & \|w\|^2/2 \\ \text{s.t. } & y_i(w \cdot x_i + b) - 1 = 0, i = 1, 2, \dots, l \end{aligned} \quad (2)$$

当训练样本集线性不可分时,需引入非负松弛变量 $\xi_i, i = 1, 2, \dots, l$, 求解最优分类面问题为:

$$\min \|w\|^2/2 + C \sum_{i=1}^l \xi_i$$

$$\begin{aligned} \text{s.t. } & y_i(w \cdot x_i + b) - 1 - \xi_i = 0, \\ & \xi_i \geq 0, i = 1, 2, \dots, l \end{aligned} \quad (3)$$

式中, C 为惩罚参数; C 越大表示对错误分类的惩罚越大. 通过 Lagrange 乘子法求解上述优化问题,得最优决策函数:

$$f(x) = \text{sgn} \left[\sum_{i=1}^l y_i \alpha_i (x \cdot x_i) + b \right] \quad (4)$$

其中 α_i 为 Lagrange 系数. 在对输入测试样本 x 进行测试时,由式(4)确定 x 的所属类别. 根据 K-T 条件,上述优化问题的解必须满足:

$$\alpha_i (y_i (w \cdot x + b) - 1) = 0 \quad (5)$$

因此,对于多数样本 α_i 将为零,取值不为零的 α_i^* 对应的样本即为支撑向量,他们通常只是全体样本中的很少一部分. 这样,仅需要少量支撑向量即可完成正确的样本分类.

当样本集非线性时,可把样本 x 映射到某个高维空间 H ,并在 H 中使用线性分类器. 根据 Mercer 条件,采用不同内积函数 $K(x_i \cdot x_j)$ 就可实现非线性的线性分类. $K(x_i \cdot x_j)$ 称为核函数,此时相应的最优决策函数变为:

$$f(x) = \text{sgn} \left[\sum_{i=1}^l y_i \alpha_i K(x \cdot x_i) + b \right] \quad (6)$$

3 基于遗传算法(GA)的决策树生成

根据分解重构法思想,一个复杂的多类问题可以划分为多个两类问题来解决. 而采取决策树的组合分类策略已被证明是一种高效的多分类组合方法. 但不同的决策树结构会对分类精度产生不同的影响,而且这种影响有可能产生“误差积累”现象. 理论上讲,对 K 类问题,所有可能构造的严格二叉树的数目为^[9]:

$$N_k = \sum_{i=1}^{K-1} (2 \cdot i - 1) \quad (7)$$

其中 $K \geq 3$. 因此,如何构造具有最优(或近优)分类性能的二叉决策树就成为 SVM 决策树组合多分类策略的关键. 传统的 DT-SVM 方法和 DAG-SVM 方法对此均没有进行深入研究. 本节采用遗传算法,以类间分类间隔(margin)最大为准则,在每个决策节点将多类训练样本划分为两类进行训练,使两个子类间的可分性尽可能强,以构造合理的树结构,最终生成最优(或近优)的决策树.

3.1 遗传算法的设计

3.1.1 编码策略

参数编码是实现 GA 的关键. 为了提高搜索效率,本文采用实值编码的策略来实现原始训练样本集类别的编码. 决策树根节点的染色体的编码为: $\{1, 2, \dots, K\}$, 其中 $K \geq 3$ 为原始训练样本集类别总数,染色体

中每个基因对应的是原始训练样本集的分类编号;对于根节点以下的子节点,根据其父节点的划分结果,剔除父节点染色体中本节点不包含的类别对应的基因,形成新的染色体。

3.1.2 初始种群的产生

采用实值编码,解空间与染色体空间重合。考虑到种群数目过大不仅增加 GA 运算时间,而且会使种群形态过于分散,从而使算法收敛困难,所以我们选择种群规模的大小为训练样本的 30%。在解空间中随机产生初始种群,并使其均匀分布于解空间。

3.1.3 适应度函数的确定

我们的目标是在每个决策节点将原始多类训练样本集划分为两类,并且使分类间隔最大。因此选择 SVM 分类算法的分类间隔作为 GA 适应度函数。

根据 SVM 理论,两类样本的最大分类间隔为:

$$m \arg \min = 2 / w^* \quad (8)$$

其中:

$$w^* = \frac{1}{n} \sum_{i=1}^n y_i x_i \quad (9)$$

3.1.4 遗传操作算子

遗传操作是实现寻优的关键,为了使染色体完整地包含当前决策节点训练样本所属的类别种类,又避免染色体基因出现重复(该情况会使划分出现交叠),本文只采用了选择操作算子和变异操作算子。

(1) 选择。选择算子的作用是从上一代的遗传结果中以一定概率繁殖适应度较大的个体进入下一代的遗传操作。若个体 a_i 的适应度函数为 $fit(a_i)$, 种群规模为 pop_size , 则选中 a_i 为下一代个体的概率为:

$$P(a_i) = pop_size \times fit(a_i) / \sum_{j=1}^{pop_size} fit(a_j) \quad (10)$$

显然适应度高的个体,繁殖的下一代数目较多;而适应度较小的个体,繁殖的数目较小,甚至被淘汰。

(2) 变异。为了在遗传操作初期取得较大的变异算子以维持种群的多样性,防止出现早熟现象;在算法已接近最优解邻域时,减小变异算子,确保其局部搜索能力,本文采用如下自适应变异概率:

$$P_m = \exp(-1.5 \times 0.5t) / pop_size \times \sqrt{L} \quad (11)$$

其中: t 是进化代数, L 是染色体长度。

此外,为了防止同一条染色体中相同基因重复出现,染色体中某一基因座上的基因发生变异时,变异后的基因编码对应的基因座上的基因应相应地变换为变异基因座上的原基因编码。例如,8 分类问题的某一原始染色体编码如图 2(a) 所示,若第二基因座上的基因发生变异,变异后的基因编码为 7,则最终变异操作得到的新染色体如图 2(b) 所示:




图 2 变异操作示意图

3.2 决策树生成算法

基于遗传算法的 SVM 决策树生成算法可描述如下:

步骤 1: 将全部训练样本集所属类别按实值编码策略进行编码,并在根节点调用 GA 将原始训练样本所属类别划分为两类。

步骤 2: 判断各子节点是否只包含一类样本,若是转步骤 4,反之转步骤 3。

步骤 3: 对包含两类以上样本的子节点,剔除其父节点染色体中本子节点不包含的类别对应的基因,形成新的染色体,并调用 GA 将本节点的样本所属类别划分为两类。转步骤 2。

步骤 4: 结束循环,生成最优(或近优)决策树。

需要说明的是,GA 是一种启发式搜索算法,因此并不能保证任何情况下生成的决策树一定是最优的,有可能是近优的。

4 算法复杂度及运行时间分析

4.1 训练及分类复杂度分析

SVM 多分类分解重构法的基本 SVM 训练方法和组合策略决定了分类器的训练及分类复杂程度。对于 K 分类问题,本文提出的方法与常见的 SVM 多分类分解重构法训练及分类复杂度的比较见表 1。

表 1 各种 SVM 多分类分解重构法训练及分类复杂度比较

	1-a-1	1-a-r	DAG	DT-SVM	GADT-SVM
基本 SVM 训练方法	一对一	一对其余	一对一	一对其余	GA 自适应生成
组合策略	投票法	最大输出	有向无环图	分类树	分类树
需训练 SVM 个数	$K(K-1)/2$	K	$K(K-1)/2$	$K-1$	$K-1$
分类所需遍历 SVM 平均个数	$K(K-1)/2$	K	$K-1$	$(K-1)(K+2)/2K$	$(K-1)(K+2)/2K$

由表 1 可见,对于基本 SVM 的训练,1-a-1 与 DAG 采用“一对一”的方法,需要训练的 SVM 最多,且随类别

数 K 的增加成平方指数增加;1-a-r 采用“一对其余”的方法,训练的复杂程度大大减少;DT-SVM 和 GADT-SVM

由于采用了树结构,训练的复杂程度最小.在分类判断时,1-a-1、1-a-r 都需要遍历所有训练的 SVM,效率很低;DAG 采用了有向无环图结构,分类所需的平均 SVM 个数有所减少;DT-SVM 采用的是固定结构的二叉树策略,分类所需的平均 SVM 个数进一步减少;本文提出的 GADT-SVM 采用的决策树由 GA 根据具体情况自适应生成,其分类判断的最坏情况等于 DT-SVM 所需的 SVM 数,具有最高的分类效率.

4.2 训练时间分析

支持向量机的训练时间与样本集的大小成超线性关系^[10], $T = ck^a$, 其中 c 为比例常数, a 为一常数, k 为训练样本集大小.对于基于分解重构法的支持向量机学习算法来说, $a > 2$, 因此, SVM 的训练时间取决于参与训练的样本的数量多少.

设模式类别数为 $K-3$, 每类样本数相等.对于标准的 1-a-r 方法,需训练 K 个 SVM, 总的训练时间为: $T_{1-a-r} = cKk^a$. 对于 DT-SVM, 虽然也采用“一对其余”的模糊类方法, 但随着树的高度的增加, 参与训练的样本数在逐级减少. 设决策树根节点高度为 0, 则高度为 i ($i = 0, 1, 2, \dots, K-2$) 的决策点训练样本数为: $k(K-i)/K$, DT-SVM 总的训练时间为: $T_{DT-SVM} = \sum_{i=0}^{K-2} c[k(K-i)/K]^a$.

对于 1-a-1 和 DAG 方法, 需要训练 $K(K-2)$ 个 SVM, 每个 SVM 的训练样本数为 $2k/K$, 总的训练时间为 $T_{1-a-1} = T_{DAG} = c \frac{K(K-1)}{2} \left(\frac{2k}{K} \right)^a 2^{a-1} cK^2 \cdot a k^a$. 当 a

2 时, 这两种方法的训练时间与类别数几乎无关.

对于本文提出的 GADT-SVM 方法, 训练时间由两部分组成, 一是 GA 在每个决策节点对树结构进行优化的时间; 二是优化结束后各个决策节点基本 SVM 的训练时间. 对优化结束后各决策节点基本 SVM 训练时间, 其

最坏情况的树结构与 DT-SVM 决策树的结构相同, 即每次决策分类, 仅将训练样本中的一类与其余类划分开来; 额外的时间开销来自 GA 对树结构的自动优化. 但对具体的分类问题, 决策树结构的优化过程通常是离线进行, 并且一旦确定, 对该问题就不再改变. 因此, 以增加离线优化时间为代价换取 SVM 决策树在线的最优 (或近优) 分类性能是可行的.

至于以上方法的分类测试时间, 由分类所需遍历 SVM 数目和每个 SVM 支持向量 (SV) 的数量共同决定, 这一方面与组合分类策略有关, 一方面与 SVM 的参数优化有关, 本文不进行深入研究. 一般来说, 分类所需遍历 SVM 的平均个数越少, 每个 SVM 的 SV 个数越少, 分类时间越短; 反之则越长.

5 数值实验

本节通过实验对 1-a-1、1-a-r、DAG-SVM、DT-SVM 及本文提出的 GADT-SVM 多分类方法进行对比. 实验采用 UCI 数据库 (<http://www.ics.uci.edu/ml/MLSummary.html>) 的 Letter 数据集. Letter 数据集是关于英文大写字母识别的数据集, 共包含 26 类, 20000 个样本, 每个样本为 16 维向量. 为了简便起见, 本文仅取 3 分类 {A, B, C}、4 分类 {A, B, C, D}、6 分类 {B, C, D, E, F, G}、7 分类 {C, D, E, G, H, I, J} 和 10 分类 {A, B, C, D, E, F, G, H, I, J} 5 种情况进行实验. 对于每类, 在数据集中任取 40 个样本作训练样本集, 100 个样本为测试样本集. 为了便于比较, 所有的基本 SVM 均采用径向基核函数: $K(x, x_i) = \exp\{-|x - x_i|^2 / (2 \cdot \sigma^2)\}$, $\sigma = 5$; 惩罚参数取 $C = 2$.

根据前面讨论的算法, GADT-SVM 对 5 种多分类情况生成的决策树如图 3(a) ~ (e) 所示.

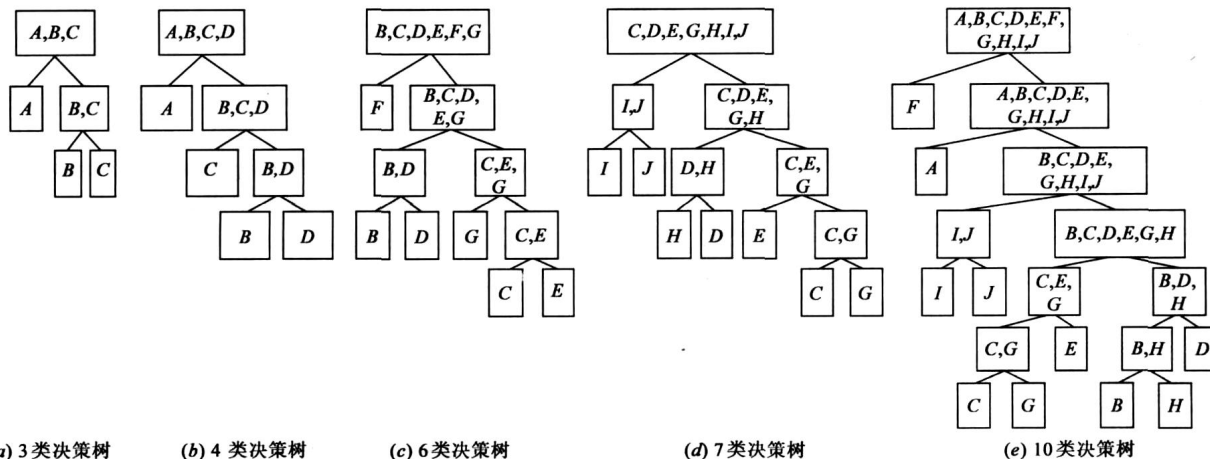


图3 GADT-SVM生成的最优 (近优) 决策树

对 DT-SVM, 在每个决策节点随机将训练样本分成两类进行训练; 对 DAG-SVM, 在每个决策节点随机取两

类进行训练. 表 2 列出了 5 种方法分别在 5 种分类情况下各 SVM 的平均支持向量数目 (# SV) 和测试所需遍

历 SVM 的平均数目 (# SVM) :

表 2 各 SVM 多分类方法平均支持向量数及测试所需 SVM 平均数对比

类 别 数	1-a-1					1-a-r					DAG-SVM					DT-SVM					GADT-SVM				
	3	4	6	7	10	3	4	6	7	10	3	4	6	7	10	3	4	6	7	10	3	4	6	7	10
# SV	38.3	43.9	44.6	42.9	44.2	53	71	99.2	114.6	135.9	38.7	41	43.8	46.2	43	44.5	56.7	76	85.3	95.3	44	50.3	61.5	64.7	71.6
# SVM	3	6	15	21	45	3	4	6	7	10	2	3	5	6	9	1.67	2.25	3.33	3.86	5.4	1.67	2.25	3	3	4.5




图 4 本文方法与传统方法分类性能比较

5 种方法在不同分类情况下的分类精度、基本 SVM 训练时间、平均分类时间如图 4 所示:

由图 4(a) 可见,随着分类类别数的增加,所有方法的分类精度都成下降趋势,其中本文方法的精度在 3 分类、4 分类、6 分类时高于经典的 1-a-r 和 1-a-1 方法的精度,在 7 分类、10 分类时与其相当,而其训练时间和分类时间则分别比 1-a-r 和 1-a-1 大大减少(见图 4(b)、(c));在所有 5 种分类情况下,经本文方法优化后的 SVM 决策树分类精度均高于未经优化的 DT-SVM 和 DAG-SVM 方法的分类精度.在图 4(b)中,1-a-r 由于每次训练都需要所有的样本参与,故其训练时间最长;1-a-1/DAG-SVM 虽训练复杂,但每次训练只需要两类样本参与,其训练时间反而最短,且与类别的变化关系不大;本文方法的基本 SVM 的训练时间优于 DT-SVM,仅次于 1-a-1/DAG-SVM,这与前面理论分析相吻合.图 4(c)中所示的分类时间由测试所需遍历的 SVM 数和单个 SVM 的平均支持向量数共同决定.由表 2 可知,1-a-1 单个 SVM 的平均支持向量数与类别数的变化关系不大,其分类时间主要由所需遍历的 SVM 数目决定.由于 1-a-1 分类需遍历所有的 SVM,其分类时间随类别的增加成指数增加;DAG-SVM 采用有向无环图结构的分类策略,所需遍历的 SVM 较少,而单个 SVM 的平均支持向量数最少,其分类时间最短;本文的方法所需遍历的 SVM 最少,但单个 SVM 的平均支持向量量较 DAG-SVM 略多,总的分类时间与 DAG-SVM 相当.

6 结论

本文提出了一种基于 GA 的 SVM 决策树多分类方

法,该方法可以根据分类问题的具体情况,利用 GA 自适应地生成最优或近优决策树,从而使分类器达到最优或近优的分类性能.文中针对 SVM 多分类问题的特点,设计了 GA 的编码策略、适应度函数及遗传算子;在此基础上提出了最优(近优)SVM 决策树的生成算法;从理论上就训练复杂度、训练时间和分类时间等方面对常见的 SVM 多分类方法和本文的方法进行了对比分析;最后进行了数值实验.分析和实验结果表明,本文提出方法的分类精度高于没有进行树/图结构优化的 DT-SVM 和 DAG-SVM 方法;训练复杂度、训练时间与经典的 1-a-1,1-a-r 方法相比大大降低,具有最好的总体性能.

参考文献:

- [1] Weston J, Watkins C. Modeling Multi-class support vector machines. Technical Report CSD-TR-98-04, Dept. of Computer Science, University of London, 1998, 1 - 10.
- [2] 李昆仑, 黄厚宽等. 模糊多类 SVM 模型[J]. 电子学报, 2004, 32(5): 830 - 832.
Li Kunlun, Huang Houkuan, et al. Fuzzy support vector machine for multi-class classification[J]. Acta Electronica Sinica, 2004, 32(5): 830 - 832. (in Chinese)
- [3] Hsu C W, Lin C J. A comparison of methods for multi-class support vector machine[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415 - 425.
- [4] Krebel U. Pairwise classification and support vector machines

- [M]. MA:MIT Press, 1999. 255 - 268.
- [5] Bottou L, Cortes C, Denker J, et al. Comparison of classifier methods: a case study in handwriting digit recognition[A]. Int Conf Pattern Recognition[C]. Jerusalem, Israel: 1994. 77 - 87.
- [6] Platt J C, Cristianini N, Shawe Taylor J. Large margin DAGs for multiclass classification[J]. Advances in Neural Information Processing Systems, 2000, 12(3): 547 - 553.
- [7] Fumitake T, Shigeo A. Decision tree-based multiclass support vector machines[A]. Proceedings of the 9th International Conference on Neural Information Processing [C]. Singapore, 2002. 1418 - 1422.
- [8] 连可, 王厚军等. 基于 SVM 的模拟电子系统多故障诊断研究[J]. 仪器仪表学报, 2007, 28(6): 1029 - 1034.
Lian K, Wang H J, et al. Study on SVM-based analog electronic system multiple fault diagnosis[J]. Chinese Journal of Scientific Instrument, 2007, 28(6): 1029 - 1034. (in Chinese)
- [9] 孟媛媛, 刘希玉. 一种新的基于二叉树的 SVM 多类分类方法[J]. 计算机应用, 2005, 25(11): 2653 - 2657.
Meng Y Y, Liu X Y. A new SVM multiclass classification based on binary tree. [J]. Computer Applications, 2005, 25(11): 2657 - 2657. (in Chinese)
- [10] Platt J C. Fast training of support vector machines using sequential minimal optimization[A]. Advances in Kernel Methods Support Vector Learning [C]. Cambridge: MIT Press, 1999. 185 - 208.

作者简介:



连 可 男, 1978 年生于重庆璧山, 2000 年, 2003 年分别于空军工程大学获战术导弹控制与测试工程专业学士学位和机械电子工程专业硕士学位; 2003 年至 2004 年就职于空军地空导弹某部; 2005 年进入电子科技大学自动化工程学院, 现为检测技术与自动化装置专业博士研究生。从事信号检测与估计及智能优化算法方面的有关研究。E-mail: lian_k@163.com



黄建国 男, 教授。1962 年生于江苏南通。1982 年于电子科技大学获电子工程专业学士学位。现为电子科技大学测试技术与仪器研究所所长, 主要从事电子工程、系统集成及测试技术与仪器方面的研究。

王厚军 男, 1961 年生于北京, 教授, 博士生导师。目前担任总装“通用测试技术”专家组成员, “全国仪器仪表专业教学指导委员会”委员, “全国电子测量与仪器学会自动测试与控制专业委员会”主任委员, 中国仪器仪表学会理事、专家委员会委员, ICCAS (International Conference on Communications, Circuits and Systems, sponsored by IEEE, ComSoc/ IEEE, CASS/ IEEE) 国际通信、电路与系统会议秘书长等。主要从事信号信息处理, 电子测试, 故障诊断等方面研究。

龙 兵 男, 1974 年出生, 现为电子科技大学副教授, 硕士生导师。主要研究方向为电子设备自动化测试、故障诊断、预测等。