

基于随机子空间和 AdaBoost 的自适应集成方法

姚 旭, 王晓丹, 张玉玺, 邢雅琼

(空军工程大学防空反导学院, 陕西西安 710051)

摘 要: 如何构造差异性大且精确度高的基分类器是集成学习的重点, 为此提出一种新的集成学习方法——利用 PSO 寻找使得 AdaBoost 依样本权重抽取的数据集分类错误率最小化的最优特征权重分布, 依据此最优权重分布对特征随机抽样生成随机子空间, 并应用于 AdaBoost 的训练过程中. 这就在增加分类器间差异性的同时保证了基分类器的准确度. 最后用多数投票法融合各基分类器的决策结果, 并通过仿真实验验证该方法的有效性.

关键词: 集成学习; 随机子空间; AdaBoost 算法; 粒子群优化

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2013) 04-0810-05

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

DOI: 10.3969/j.issn.0372-2112.2013.04.031

A Self-Adaption Ensemble Algorithm Based on Random Subspace and AdaBoost

YAO Xu, WANG Xiao-dan, ZHANG Yu-xi, XING Ya-qiong

(School of Air and Missile Defense, Air Force Engineering University, Xi'an, Shaanxi 710051, China)

Abstract: It is an open issue how to generate base classifiers with higher diversity and accuracy for ensemble learning. In this paper, a novel algorithm is proposed to solve this problem—particle swarm optimization is used to search for an optimal feature weight distribution which makes the classification error rate of training data sample by the distribution in AdaBoost minimal. Then, the feature subspace is constructed according to the optimal feature weight distribution, which is applied into the training process of AdaBoost. Thus, the accuracy of base classifier is advanced; meanwhile, the diversity between classifiers is improved. Finally, majority voting method is utilized to fuse the base classifiers' results and experiments have been done to attest the validity of the proposed algorithm.

Key words: ensemble learning; random subspace; AdaBoost algorithm; particle swarm optimization

1 引言

集成学习是模式识别和机器学习领域研究的热点问题. 由于它能够显著提高学习系统的泛化性能^[1], 因此受到了越来越多的关注. 目前, 集成学习已经被成功应用于基因数据分析^[2]、图像处理^[3]、文本分类^[4]等很多实际应用问题. 常用的集成方法有 Bagging^[5], AdaBoost^[6], RSM^[7]等. 在这些方法中, AdaBoost 以其简单、适应性强等特点成为比较流行的一种, 受到了很多研究者的关注^[8-10]. 它通过使分类器专注于难分样本增加了分类器间的差异性, 但是忽略了其余样本有时又会导致它的不精确性. RSM 是一种基于特征划分的集成方法, 常用于增强集成分类器间的独立性. 它能够有效的降低特征维数, 同时也降低了样本本身的冗余, 尤其适用于解决高维数小样本问题. 如王雪松等^[11]提出了基于随机子空间-正交局部保持投影的支持向量机并应用于典型人脸数据库识别; Kuncheva 等^[12]将 RSM 成功用

于功能性磁共振成像的分类; Yang 等^[13]为解决超光谱成像分类问题提出了动态子空间方法等. 但是 RSM 也存在着一定的缺陷, 由于特征子集是随机选取的, 可能导致所选特征并不一定包含对分类有贡献的判别信息, 因此增加差异性的同时并不能保证基分类器的准确性.

鉴于 RSM 和 AdaBoost 这两种集成方法的优缺点, 本文试图将二者结合, 提出一种融合 RSM 和 AdaBoost 的新的集成方法 R-AdaB, 以期获得更小的分类误差. 研究表明直接将 RSM 和 AdaBoost 简单结合并不能得到令人满意的结果^[14]. 原因是基于 RSM 构造的基分类器大多数性能不高. 而本文将引入 PSO 寻优算法来获得随机子空间并在相应的数据集上训练基分类器. 下面就详细介绍新方法的具体实现过程并给出实验结果和分析.

2 融合 RSM 和 AdaBoost 的集成方法

R-AdaB 方法的创新点在于将 RSM 融入到 AdaBoost 的训练过程中——通过一定准则得到特征权重分布并

不断更新,根据更新的样本权重分布和特征权重分布来选择训练集用于 AdaBoost 的训练,这样在更新样本权重的同时也更新了特征权重.在该方法中样本权重仍然按照 AdaBoost 算法进行更新,特征权重则通过在对对应数据集上执行优化搜索算法,旨在寻找使得该数据集分类错误率最小的一组权重因子.下面将给出最优特征权重的生成方法和 R-AdaB 方法的具体实现步骤.

2.1 最优特征权重分布

本文选用粒子群算法^[15]作为寻找最优权重的搜索算法.文献^[16]在证明了 PSO 进化过程与粒子速度无关的基础上提出了简化粒子群优化算法(SPSO).SPSO 进化公式为:

$$x_{ij}^{k+1} = \omega x_{ij}^k + c_1 r_1 (p_{ij} - x_{ij}^k) + c_2 r_2 (p_{gj} - x_{ij}^k) \quad (1)$$

其中, x_{ij}^k 表示第 k 代第 i 个粒子的第 j 维分量, r_1 和 r_2 是 $(0,1)$ 之间的随机数, c_1 和 c_2 为学习因子, ω 为惯性因子, p_{ij} 为第 i 个粒子当前搜索到的最优位置的第 j 维分量, p_{gj} 为整个粒子群当前最优位置的第 j 维分量.

针对 PSO 容易陷入局部收敛,本文引入 t 分布变异.当 PSO 陷入局部收敛时,利用 t 算子对群体极值 P_{gbest} 进行变异,使其跳出局部收敛.文中通过计算粒子与 P_{gbest} 的距离来判断各个粒子是否聚集到群体极值 P_{gbest} .由于在开始阶段变异尺度应该尽可能大,使得粒子群能够在更广阔的空间进行搜索,加快收敛速度.随着进化代数的增加,粒子群不断向全局最优值靠近,此时变异尺度应该动态的减小,避免变异程度太大,使粒子远离全局最优值.因此定义一个动态变化的 t 分布变异尺度:

$$\sigma_j(k) = \left[\alpha^k \cdot \frac{f_{\max}(k) - f_{\min}(k)}{f_{\max}(k)} + (1 - \alpha^k) \cdot \alpha^k \right] \cdot (P_{\text{gbest}}^{\max} - P_{\text{gbest}}^{\min}) \quad (2)$$

其中, $f_{\max}(k)$ 和 $f_{\min}(k)$ 分别是第 k 代最好和最差粒子的适应度值. P_{gbest}^{\max} 和 P_{gbest}^{\min} 是群体极值 P_{gbest} 的最大值和最小值. α 是一个比 1 略小的常数,根据最大进化代数取值. $[f_{\max}(k) - f_{\min}(k)]/f_{\max}(k)$ 表示变异尺度根据每一代中最好和最差适应度值进行自适应的调整.为了避免在进化开始阶段整体变异幅度太大,我们用 α^k 对其进行限制.因此定义基于 t 分布的 P_{gbest} 变异公式为:

$$P'_{\text{gbest}} = P_{\text{gbest}} + \sigma_j * t_n \quad (3)$$

利用 PSO 对特征权重分布进行寻优,实际上就是一个以分类正确率为适应度函数的特征选择的过程.为了保持连续 PSO 的特性,在搜索过程中,做如下处理:将特征选择问题表示成一个由 0 和 1 组成的向量 $F_i = (f_{i1}, f_{i2}, \dots, f_{in})$, $f_{ij} = 1$ 表示第 j 维特征被选中,否则被淘汰.定义位置向量向特征向量的转化公式为:

$$f_{ij} = \begin{cases} 1, & x_{ij} \geq r_0 \\ 0, & \text{else} \end{cases} \quad (4)$$

其中 r_0 是区间 $(0.2, 0.8)$ 上的随机数.

下面给出基于 PSO 的最优特征权重分布生成算法 FWO(Feature Weight Optimization):

输入:训练集 $D = \{(\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2), \dots, (\mathbf{x}_N, \mathbf{y}_N)\}$. $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$, $\mathbf{y}_i = \{y_1, y_2, \dots, y_c\}$. PSO 迭代次数为 S . 种群大小为 P . 变异次数为 m . 距离阈值 δ .

输出:最优权重向量.

Step1:生成 P 个初始粒子,即生成一个 $P \times d$ 矩阵,矩阵中每一个元素是 $(0,1)$ 之间的随机数,并按照式(4)将粒子转化成特征向量;

Step2:计算每个粒子的适应度值,将粒子的个体极值 P_i 设置为当前位置,群体极值 P_{gbest} 设置为初始群体中最佳粒子的位置;

Step3:判断算法是否满足收敛条件(群体最大适应度满足条件或达到最大迭代次数),如果满足,转向 Step6,否则转向 Step4;

Step4:对于群体中的所有粒子,根据式(1)进行位置更新,计算适应度值,如果 P_i 和 P_{gbest} 优于历史最优位置,则更新 P_i 和 P_{gbest} ;

Step5:判断粒子群是否聚集到 P_{gbest} ,如果否,转向 Step3. 否则根据式(3)对 P_{gbest} 进行 m 次变异,得到 P'_{gbest} . 如果 P'_{gbest} 优于 P_{gbest} ,则 $P_{\text{gbest}} = P'_{\text{gbest}}$, 转向 Step3, 否则转向 Step6;

Step6:输出 P_{gbest} , 算法结束.

2.2 R-AdaB 方法具体步骤

下面给出融合 RSM 和 AdaBoost 的集成方法 R-AdaB 的具体步骤:

输入:训练集 $D = \{(\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2), \dots, (\mathbf{x}_N, \mathbf{y}_N)\}$. 基学习算法 W , AdaBoost 的迭代次数 T . PSO 的迭代次数 S . 种群大小 P . 随机子空间中特征维数 r ;

输出:总体分类器的判决函数值: $H(\mathbf{x}) = \text{sign} \left[\sum_{t=1}^T \alpha_t h_t(\mathbf{x}) \right]$;

Step1:初始化各样本对应的权值:

$$w_1(i) = 1/N, i = 1, \dots, N;$$

Step2:for $t = 1$ to T

(1)利用 FWO 算法得到最优特征权重分布 β_t , 依据 β_t 和 w_t 训练基分类器 C_t 得到 h_t ;

(2)计算 C_t 的训练误差 ϵ_t : $\epsilon_t = \sum_{i=1}^N w_t(i) \cdot y_i \neq h_t(\mathbf{x}_i)$, 即 ϵ_t 相当于错分样本的权值 w_t 之和;

(3)设置弱分类器 C_t 的权值:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right);$$

(4)更新训练样本的权值:

$$w_{t+1}(i) = \frac{w_t(i) \exp\{-\alpha_t y_i h_t(\mathbf{x}_i)\}}{Z_t}$$

$$= \frac{w_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t}, & \text{if } y_i = h_t(\mathbf{x}_i) \\ e^{\alpha_t}, & \text{if } y_i \neq h_t(\mathbf{x}_i) \end{cases}$$

其中 Z_t 为归一化系数,使 $\sum_{i=1}^N w_{t+1}(i) = 1$.

Step3:对测试样本 \mathbf{x} ,融合各分类器的输出结果:

$$H(\mathbf{x}) = \text{sign} \left[\sum_{i=1}^T \alpha_i h_i(\mathbf{x}) \right].$$

3 实验结果及分析

3.1 实验数据及参数设置

实验中的数据均来自 UCI 数据库中的数据,实验选择了其中 9 组数据(特征维数范围为 4~60,样本范围为 208~2310),关于实验数据的详细描述见表 1.

表 1 UCI 数据集各数据描述

编号	数据集	样本数	维数	类别
1	Sonar	208	60	2
2	Ionosphere	351	34	2
3	Diabetes	768	8	2
4	Breast-w	699	9	2
5	Heart-statlog	270	13	2
6	Soybean	307	35	19
7	Vehicle	846	18	4
8	Segment	2310	19	7
9	Balance	625	4	5

在 FWO 算法中,惯性权重 ω 采用文献[17]的策略.距离阈值 δ 是算法中的一个关键参数.如果设置的过大,实际上粒子没有收敛到群体极值 P_{gbest} 而被误判为收敛到 P_{gbest} ,从而对 P_{gbest} 进行变异,这样就延长了搜索时间.如果设置的过小,则可能会把实际上已经收敛到 P_{gbest} 判断为未收敛到 P_{gbest} ,这样就无法及时跳出局部收敛.经过多次实验,本文设定 $\delta = 0.5d_0$,其中 d_0 是初始粒子群中各个粒子与群体最优粒子的欧氏距离的均值.为了更好的实现变异操作,利用不同的 t 算子对群体极值进行变异,选择其中最好的结果.选用的算子有 $t_{1.5}, t_2, t_{2.5}, t_3, t_{10+k}$ (k 为进化的代数).种群大小 $N = 30$,PSO 最大迭代次数 $S = 100$,变异次数 $n = 100$,学习因子 $c_1 = c_2 = 2$, $\alpha = 0.97$,AdaBoost 迭代次数 $T = 50$.实验中各个算法的适应度函数均为分类正确率.

在估计分类错误率时采用 10 重交叉验证来进行,并利用双边估计 t 检验法来计算置信水平为 0.95 的分类错误率置信区间作为最终结果,计算公式如下:

$$\frac{|\bar{x} - \mu|}{\sigma/\sqrt{n}} \geq t_{0.025}(n-1) \quad (5)$$

μ, σ 分别表示 10 重交叉验证的均值和标准差, $t_{0.025}(9)$

$= 2.2622$.实验中成员分类器均来自 PRTTool (<http://www.prtools.org>) 工具箱, SVM 采用径向基核函数的 SVM,其中参数 $C = 1000$, σ 依照文献[18]选取.实验机器配置为 2G 内存,2.80G CPU,算法基于 Matlab7.10 (R2010a)实现.

3.2 实验结果和分析

为了验证 R-AdaB 方法的性能,与单分类器, Bagging, AdaBoost 和 RSM 进行比较.实验选取支持向量机 (Support Vector Machine, SVM) 和决策树 (Decision Tree, DT) 作为基分类器,从分类误差和差异性两个角度对本文提出的方法进行验证.

3.2.1 实验结果和分析

实验中采用 10 重交叉验证法来估计分类误差.在每个数据集上进行 10 次实验,实验结果取 10 次实验的平均值. Bagging, AdaBoost, RSM, R-AdaB 的集成规模均为 50.实验结果如表 2 和表 3 所示.各个数据集上最小的分类误差在表中加粗表示.分析表 2 可以看出,当选取 SVM 为分类器时,除了在 Sonar 和 Heart-statlog 数据集上,本文提出的方法均获得了最小的分类误差.从表 2 的实验结果也可以看出,当以 SVM 这种稳定的学习算法为基分类器时, Bagging、RSM 等仅依靠对训练集进行扰动构造差异性的集成方法有时并不能得到比单分类器更好的分类效果.尤其是对于 RSM,与单分类器相比,平均分类误差降低了 0.71%.对于特征维数较低的样本, RSM 的分类效果较差,如 Balance 数据集.分析表 3 可以看出,当选取 DT 为分类器时,除了在 Segment 和 Balance 两个数据集上,本文提出的方法均获得了最小的分类误差.因此本文所提方法能够获得更高的性能.

表 2 五种方法的分类误差及置信水平为 0.95 的置信区间(%) (SVM)

No.	SVM				
	Single	Bagging	AdaBoost	RSM	R-AdaB
1	15.88 ± 6.13	14.92 ± 4.76	10.61 ± 5.50	15.39 ± 6.40	11.02 ± 4.62
2	10.22 ± 2.65	8.79 ± 4.05	9.85 ± 2.76	8.31 ± 3.45	7.95 ± 3.01
3	25.57 ± 2.75	26.37 ± 2.29	24.39 ± 2.79	25.08 ± 3.16	23.66 ± 1.99
4	6.99 ± 1.98	5.55 ± 1.74	6.11 ± 2.19	4.84 ± 1.44	3.97 ± 1.98
5	28.06 ± 6.12	26.59 ± 6.68	24.82 ± 6.32	23.53 ± 6.25	24.35 ± 4.91
6	5.25 ± 3.57	3.31 ± 2.21	5.21 ± 2.54	5.46 ± 2.53	2.96 ± 2.05
7	3.33 ± 1.19	3.19 ± 1.59	2.77 ± 1.08	2.94 ± 1.33	2.58 ± 0.71
8	4.11 ± 0.91	4.55 ± 0.91	4.11 ± 0.78	4.07 ± 1.18	3.61 ± 0.89
9	0.33 ± 0.49	1.09 ± 0.91	0.20 ± 0.37	16.47 ± 4.18	0.15 ± 0.36

为了使分类误差的描述更为清晰,我们用统计的观点对文中所涉及分类算法的相对性能进行分析^[19].表 4 给出了在所有数据集上,每种方法的误差比较.表的第一行是每种方法的误差在所有数据集上的平均值.如果用“row”表示表的每一行所列方法的误差,“col”表示表的每一列所列方法的误差,则表 4 中“ r ”一行的值表示“row/col”的几何平均值.“ s ”对应的行给出的是

win/tie/loss 统计量,其中的三个值分别表示 col < row, col = row, col > row 的数据集个数.

从表 4 的实验结果可以看出,无论分类器选择 SVM 还是 DT, R-AdaB 方法都具有最小的平均误差. 分析平均误差、“r”和“s”三个统计量可以看出,四种集成方法按照分类效果由好到差依次为 R-AdaB, AdaBoost, Bagging, RSM. 单独考虑 R-AdaB 的分类效果,它与 Single 的误差比率的几何平均值比其它方法相对于 Single 的误差比率的几何平均值都小,同时,与 Bagging, AdaBoost, RSM 的误差比率的几何平均值也表明本文所提方法的效果比较好. 此外,与其他四种方法相比, R-AdaB 在更多的数据集上有较小的分类误差. 实验结果表明该方

法有效的提高了集成的性能.

表 3 五种方法的分类误差及置信水平为 0.95 的置信区间(%) (DT)

No.	DT				
	Single	Bagging	AdaBoost	RSM	R-AdaB
1	31.88 ± 6.21	27.87 ± 5.76	25.02 ± 5.85	34.74 ± 7.07	23.93 ± 8.25
2	11.08 ± 3.27	10.62 ± 2.63	8.69 ± 2.84	7.85 ± 3.29	7.37 ± 2.92
3	32.07 ± 4.32	33.44 ± 4.58	31.04 ± 4.69	31.32 ± 4.72	30.44 ± 2.83
4	4.78 ± 1.38	3.99 ± 1.63	4.80 ± 1.34	4.28 ± 1.56	3.59 ± 1.59
5	34.99 ± 4.05	33.68 ± 4.72	33.81 ± 3.86	36.01 ± 4.84	33.04 ± 6.87
6	4.14 ± 1.57	3.02 ± 2.47	3.89 ± 2.54	3.14 ± 2.07	1.72 ± 1.86
7	9.59 ± 1.26	12.02 ± 1.87	7.97 ± 2.19	10.85 ± 2.75	7.22 ± 1.47
8	4.98 ± 1.87	3.97 ± 1.51	3.28 ± 0.95	3.94 ± 1.28	3.29 ± 1.10
9	14.17 ± 4.34	10.97 ± 3.24	13.05 ± 2.12	13.21 ± 3.15	12.59 ± 2.26

表 4 每种方法在各个数据集上的误差(Error)比较

Algorithm	SVM					DT				
	Single	Bagging	AdaBoost	RSM	R-AdaB	Single	Bagging	AdaBoost	RSM	R-AdaB
Mean error (%)	11.08	10.48	9.79	11.79	8.92	16.41	15.51	14.62	16.15	13.69
Single	r	1.037	0.852	1.398	0.705		0.902	0.866	0.913	0.734
	s	6/0/3	8/1/0	7/0/2	9/0/0		7/0/2	8/0/1	6/0/3	9/0/0
Bagging	r		0.822	1.348	0.680			0.960	1.012	0.813
	s		6/0/3	6/0/3	9/0/0			5/0/4	4/0/5	8/0/1
AdaBoost	r			1.640	0.827				1.054	0.847
	s				4/0/5				3/0/6	8/0/1
RSM	r				0.504					0.804
	s				8/0/1					9/0/0

3.2.2 差异性比较

为了得出更具统计意义的实验结论,利用秩和检验法对上面的结果进行分析,秩水平计算如下:

$$R_j = \frac{1}{J} \sum_i r_i^j \quad (6)$$

式中 r_i^j 为在第 i 个数据集上用第 j 种方法所得到的秩大小, J 为每种方法所进行的实验次数,文中 $J = 10$. 表 5 给出了每种方法误差的秩和平均数.

表 5 各种方法误差秩和平均数比较

Algorithm	Single	Bagging	AdaBoost	RSM	R-AdaB
Error(SVM)	3.9	3.3	2.4	2.7	1.1
Error(DT)	3.9	2.8	2.5	3.2	1.1
Global Rank	3.9	3.05	2.45	2.95	1.1

从表 5 可以看出 R-AdaB 所得到的秩和平均数最小,均为 1.1, AdaBoost 次之, Single 最大. 为了验证这五种方法的分类效果具有统计意义上的显著差别,我们利用 Nemenyi 检验方法——即两种方法具有显著性差异当此两种方法的秩和平均差大于临界值 CD (Critical Difference value)^[20]:

$$CD = q_\alpha \sqrt{\frac{k(k+1)}{6J}} \quad (7)$$

其中 q_α 可通过查询“The Studentized Range Statistic”表得

到, k 为所要验证的方法数, J 为每次实验的次数. 在本实验中我们比较了 5 种方法在置信水平为 $\alpha = 0.05$ 下的分类效果,即 $k = 5, q_{0.05} = 1.860$,代入式(7)可得差异临界值(CD)为 1.315. 观察表 5 可知 R-AdaB 与 Single、Bagging、AdaBoost、RSM 的秩和平均差分别为 2.8, 1.95, 1.35, 1.85, 均大于差异临界值. 因此本文方法的分类效果与其它几种方法具有统计意义上的显著差别. 同时,本文方法能够获得更小的分类误差,因此本文提出方法是可行的,它能够有效的提高集成系统的性能.

4 结论

本文提出了一种新的集成方法 R-AdaB. 该方法的主要思想是借鉴 AdaBoost 算法中样本权重更新的思想对特征的权重进行更新,使得 RSM 依权重分布生成特征子空间. 特征权重更新的准则是最小化由 AdaBoost 依样本权重随机抽样生成的训练样本的分类错误率. 这样 AdaBoost 每一次抽取的样本的特征权重都不尽相同,包含分类信息越多的特征的权重就越大,该特征被选中的概率也越大. 因此利用由最小化分类错误率准则生成的特征子空间训练分类器可以有效的提高基分类器的性能. 而且由于每次抽取的特征是最适合相应训练样本的特征,因此每次生成的特征子集都具有差异性,这也就提高了基分类器间的差异性. 实验表明本文

方法在保证差异性的前提下,能有效提高基分类器的正确率,从而提高了集成系统的性能.此外,为了提高正确率,本文选用搜索算法 PSO 进行特征权重的寻优,这在运行效率上虽然不及 AdaBoost,但是对于样本数不大的数据集,两者的运行效率相差并不是很大.如何提高在大样本上的运行效率是作者今后研究的方向.

参考文献

- [1] Dietterich TG. Machine learning research; four current directions[J]. AI Magazine, 1997, 18(4): 97 – 136.
- [2] Liu Kun-Hong. Cancer classification using rotation forest[J]. Computers in Biology and Medicine, 2008, 38(5): 601 – 610.
- [3] Kim TK. Boosted manifold principal angles for image set-based recognition[J]. Pattern Recognition, 2007, 40(9): 2475 – 2484.
- [4] Schapire RE. BoosTexter: A boosting-based system for text categorization[J]. Machine Learning, 2000, 39(2-3): 135 – 168.
- [5] L Breiman. Bagging predictors[J]. Machine Learning, 1996, 24(2): 123 – 140.
- [6] Y Freund. Experiments with a new boosting algorithm[A]. Proceedings of the 13th International Conference on Machine Learning[C]. Italy: Morgan Kaufmann, 1996. 148 – 156.
- [7] Ho, TK. The random subspace method for constructing decision forests[J]. IEEE Transaction on Pattern Analysis and Machine Intelligence. 1998, 20(8): 832 – 844.
- [8] 文学志, 等. 一种基于类 Haar 特征和改进 AdaBoost 分类器的车辆识别算法[J]. 电子学报, 2011, 38(5): 1121 – 1126.
Wen Xue-zhi, et al. An algorithm based on Haar-like features and improved AdaBoost classifier for vehicle recognition[J]. Acta Electronica Sinica, 2011, 38(5): 1121 – 1126. (in Chinese)
- [9] 王改革, 等. 基于 Elman-AdaBoost 强预测器的目标威胁评估模型及算法[J]. 电子学报, 2012, 40(5): 901 – 906.
Wang Gai-ge, et al. The model and algorithm for the target threat assessment based on Elman-AdaBoost strong predictor[J]. Acta Electronica Sinica, 2012, 40(5): 901 – 906. (in Chinese)
- [10] Ankit Desai, PM Jadav. An empirical evaluation of AdaBoost extensions for cost-sensitive classification[J]. International Journal of Computer Applications, 2012, 44(13): 34 – 41.
- [11] 王雪松, 高阳, 程玉虎. 基于随机子空间-正交局部保持投影的支持向量机[J]. 电子学报, 2011, 39(8): 1746 – 1750.
Wang Xue-song, Gao Yang, Cheng Yu-hu. Support vector machine based on random subspace and orthogonal locality preserving projection[J]. Acta Electronica Sinica, 2011, 39(8): 1746 – 1750. (in Chinese)

- [12] LI Kuncheva, JJ Rodríguez, CO Plumpton, et al. Random subspace ensembles for fMRI classification[J]. IEEE Transactions on medical imaging, 2010, 29(2): 531 – 542.
- [13] JM Yang, BC Kuo, PT Yu, et al. A dynamic subspace method for hyper spectral image classification[J]. IEEE Transactions on geoscience and remote sensing, 2010, 48(7): 2840 – 2853.
- [14] N Garcia-Pedrajas, et al. Boosting random subspace method[J]. Neural Networks, 2008, 21(9): 1344 – 1362.
- [15] Kennedy J, Eberhart R. Particle swarm optimization[A]. Proceedings of IEEE International Conference on Neural Networks[C]. Perth: IEEE Press, 1995. 1942 – 1948.
- [16] HU Wang, LI Zhi-shu. A simpler and more effective particle swarm optimization algorithm[J]. Journal of Software, 2007, 18(4): 861 – 868.
- [17] 高岳林, 任子晖. 带有变异算子的自适应粒子群优化算法[J]. 计算机工程与应用, 2007, 43(25): 43 – 47.
Gao Yue-lin, Ren Zi-hui. Adaptive particle swarm optimization algorithm with mutation operator[J]. Computer Engineering and Applications, 2007, 43(25): 43 – 47. (in Chinese)
- [18] 王晓丹, 等. 一种基于 AdaBoost 的 SVM 分类器[J]. 空军工程大学学报(自然科学版), 2006, 7(6): 54 – 57.
Wang Xiao-dan, et al. A combined SVM classifier based on AdaBoost[J]. Journal of Air Force Engineering University (Natural Science Edition), 2006, 7(6): 54 – 57. (in Chinese)
- [19] GI Webb. MultiBoosting: A technique for combining boosting and wagging[J]. Machine Learning, 2000, 40(2): 159 – 196.
- [20] J Demsar. Statistical comparisons of classifiers over multiple data sets[J]. Journal of Machine Learning Research, 2006, 7(1): 1 – 30.

作者简介



姚旭女, 1982 年 10 月出生, 河北昌黎人, 博士生. 主要研究方向为智能信息处理和机器学习等.
E-mail: ffxyl32@163.com



王晓丹女, 1966 年 10 月出生, 陕西汉中, 教授, 博士生导师. 主要研究方向为模式识别, 智能信息处理和机器学习等.