

基于随机子空间-正交局部保持投影的支持向量机

王雪松, 高 阳, 程玉虎

(中国矿业大学信息与电气工程学院, 江苏徐州 221116)

摘 要: 针对高维数、小样本数据分类问题, 提出一种基于随机子空间-正交局部保持投影的支持向量机. 利用随机子空间方法对原始高维样本的特征空间进行多次随机采样, 生成多个具有不同特征子集的基支持向量机(SVM)分类器; 利用正交局部保持投影对各基 SVM 分类器的样本进行特征提取, 实现维数约简; 然后, 利用降维后的样本对各基 SVM 分类器进行训练; 采用贝叶斯求和准则将各基 SVM 的分类结果进行融合以得到最终的分类结果. 典型人脸数据库识别结果验证了本方法的可行性和有效性.

关键词: 随机子空间; 正交局部保持投影; 支持向量机; 特征提取

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112 (2011) 08-1746-05

Support Vector Machine Based on Random Subspace and Orthogonal Locality Preserving Projection

WANG Xue-song, GAO Yang, CHENG Yu-hu

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: In order to deal with the classification problem for high-dimensional and small-sized data, a kind of support vector machine based on random subspace and orthogonal locality preserving projection was proposed. The random subspace method was used to select a feature subset from the original feature space randomly for several times. Based on the selected feature subset, several base support vector machine (SVM) classifiers were generated. The orthogonal locality preserving projection method was adopted to carry out feature extraction on the samples of each base classifiers, which can, effectively, realize dimensionality reduction. We applied the processed samples to train each base classifiers. The results of the base SVM classifiers were integrated to obtain the final classification result, using a bayesian sum rule. Results on two publicly available face databases show the feasibility and validity of our proposed method.

Key words: random subspace; orthogonal locality preserving projection; support vector machine; feature extraction

1 引言

支持向量机(Support Vector Machine, SVM)是由 Vapnik 在统计学习和 VC 维的理论基础上发展起来的学习机器, 在文本分类、图像识别、入侵检测、生物信息等领域得到了较为成功的应用, 表现出了优良的性能^[1]. 尽管支持向量机学习方法的优点主要表现在学习器的泛化能力与输入特征矢量的维数无关, 但是如果输入矢量维数增加, 支持向量机的计算复杂性和空间复杂性将急剧增加, 从而导致训练时间长和耗用内存资源大. 通常可以从两个方面来解决这个问题: 一种是训练算法的改进, 如序贯最小优化算法^[2]; 另一种改进方法是通过简化训练数据集来降低计算复杂性, 主要包括特征选择和

特征提取两种途径. 特征选择法通过从输入特征中选择一部分相关(或重要)的子集, 并剔除不相关的特征来达到简化数据集的目的. 特征提取的任务是通过对高维的输入特征进行某种数学变换, 将数据投影到一个低维空间, 获得新的低维特征, 以减少训练时间和存储空间的开销.

常用的特征提取方法有主成分分析(Principle Component Analysis, PCA)^[3]、独立成分分析(Independent Component Analysis, ICA)^[4]和线性判别分析(Linear Discriminant Analysis, LDA)^[5]等. 这几种特征提取方法具有坚实的理论基础, 易于实现和分析, 但是它们均为全局线性方法, 无法揭示数据内在的非线性结构. 为了实现非线性特征提取, 可以借助于核技巧或核技术, 将传统的线

性技术核化,如 Meng 等提出的基于核 PCA 的模糊支持向量机,并将其应用于雷达发射信号的分类^[6];应自炉等提出的基于支持向量鉴别分析的人脸表情识别算法^[7].但是,核化的特征提取方法往往依赖于某种隐式映射,不易直观地理解其工作机理,并且如何选择核函数及确定最优的核参数尚无可靠的理论依据.另一类重要的非线性特征提取技术是基于局部特性的流形学习方法,如 2003 年 He 等提出的局部保持投影(Locality Preserving Projection, LPP)算法^[8].与经典的 PCA、ICA 和 LDA 等全局保持方法不同, LPP 能够保持数据的局部拓扑结构信息.然而,由于 LPP 方法所取得的基向量并不是正交的,这使得重构数据很困难.针对这一问题, Cai 等提出了正交局部保持投影(Orthogonal LPP, OLPP)方法^[9].该方法能够获得一组正交基向量,而且比 LPP 方法具有更强的局部保持能力.

除了高维数据易于导致维数灾难之外,由于支持向量机采用的是典型的监督学习机制,过少的训练样本将导致学习器的泛化性能下降.另外,支持向量机的学习性能在很大程度上还取决于核函数及参数的合理配置.集成学习通常能获得比单一学习器更好的性能,且其学习结果对各基学习器的具体参数设置并不敏感^[4].进一步,理论和实验表明,如果用于集成的学习器之间相互独立,将可以得到最佳的学习精度.目前,随机子空间方法常用于增强集成分类器之间的独立性.为此,针对高维、小样本数据分类问题,提出一种基于随机子空间正交局部保持投影的支持向量机(Random Subspace and Orthogonal Locality Preserving Projection-Based SVM, RSOLPP-SVM),并将其应用于人脸识别问题.

2 基于随机子空间正交局部保持投影的支持向量机

RSOLPP-SVM 的设计思路为:首先,利用随机子空间方法对原始高维样本的特征空间进行随机采样,生成多个具有不同特征子集的基 SVM 分类器;其次,利用正交局部保持投影对各基 SVM 分类器的样本进行特征提取,实现维数约简;然后,利用降维后的样本对各基 SVM 分类器进行训练;最后,采用合适的集成准则将各 SVM 的分类结果进行融合以得到最终的分类结果.

2.1 随机子空间采样

随机子空间方法最早是由 Ho 提出的,最初是为了克服决策树分类器中存在的过学习问题,以提高分类器的泛化性能^[10].设 SVM 的原始样本集为 $X = [x_1, \dots, x_i, \dots, x_n] \subset R^{M \times n}$,其中 n 为样本个数, M 为样本维数.根据均匀分布,在 X 上随机抽取 D 个不同的子空间,得到新样本集 $X^d = [x_1^d, \dots, x_i^d, \dots, x_n^d] \subset R^{p \times n}$,其中

$d = 1, 2, \dots, D, p$ 为随机子空间的特征维数且 $p < M$.利用新样本集 X^d 可以建立一个 SVM 分类器 $\tilde{\varphi}^d(x)$,如此重复对样本集 X 进行 D 次随机采样则可以建立 D 个具有不同特征子集的 SVM 分类器.

2.2 正交局部保持投影降维

虽然随机子空间的特征维数低于原始样本集的维数,具有一定的降维效果,但是为了进一步降低 SVM 的计算复杂性和空间复杂性,需要利用 OLPP 对定义在各随机子空间上的 SVM 的样本进行特征提取. OLPP 的核心思想是在特征值求解过程中增加了正交约束^[9],算法步骤如下所述:

Step 1 PCA 降维.将样本数据 x_i^d 投影到 PCA 子空间上,去除特征值为 0 的特征. PCA 的转换矩阵用 W_{PCA} 来表示.通过 PCA 降维,保留绝大部分信息,降低维数,尽可能去除“噪声”.

Step 2 构建邻接图 G .计算任意样本 x_i^d 与其它样本点之间的欧氏距离,如果点 $x_j^d (j = 1, 2, \dots, n; j \neq i)$ 属于离 x_i^d 最近的 h 个样本点之一,则认为它们是近邻点,即邻接图 G 有边 $x_i^d x_j^d$.

Step 3 定义权重矩阵 $S = [S_{ij}]_{n \times n}$.如果邻接图 G 有边 $x_i^d x_j^d$,则给该边赋予权重 $S_{ij} = e^{-\|x_i^d - x_j^d\|^2 / 2\sigma^2}$,否则 $S_{ij} = 0$,其中 σ 为事先给定的控制参数.

Step 4 计算投影矩阵.定义对角矩阵 B ,其对角线上的元素 $B_{ii} = \sum_j S_{ij}$;拉普拉斯矩阵 $L = B - S$;投影矩阵 $W_{OLPP} = [a_1, a_2, \dots, a_k, \dots, a_m]$, $k = 2, \dots, m$, m 为投影向量个数.并令 $A^{(k-1)} = [a_1, \dots, a_{k-1}]$, $C^{(k-1)} = [A^{(k-1)}]^T (X^d B (X^d)^T)^{-1} A^{(k-1)}$,则各投影向量 $\{a_1, a_2, \dots, a_k, \dots, a_m\}$ 可由以下迭代过程获得:

(1) 计算 a_1, a_1 为矩阵 $(X^d B (X^d)^T)^{-1} X^d L (X^d)^T$ 对应最小特征值的特征向量.

(2) 计算 a_k, a_k 为 $Q^{(k)}$ 对应最小特征值的特征向量,其中 $Q^{(k)} = \{I - (X^d B (X^d)^T)^{-1} A^{(k-1)} [C^{(k-1)}]^{-1} [A^{(k-1)}]^T\} \cdot (X^d B (X^d)^T)^{-1} X^d L (X^d)^T$.

Step 5 特征提取.投影矩阵 $W^d = W_{PCA} W_{OLPP}$.对于样本 X^d ,特征提取 $Y^d = (W^d)^T X^d$,得到新样本 $Y^d = [y_1^d, \dots, y_i^d, \dots, y_n^d] \subset R^{m \times n}$.

2.3 支持向量机分类

设训练样本集 $\{(y_i^d, z_i)\}_{i=1}^n$,样本 $y_i^d \in R^m, z_i \in \{-1, +1\}$ 为类别标签. SVM 通过求解式(1)找到一个具有最大间隔的超平面^[1]:

$$\begin{aligned} \min_{w, b, \xi} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^n \xi_i \\ \text{s.t.} \quad & \begin{cases} z_i[(w \cdot y_i^d + b) + \xi_i - 1] \geq 0 \\ \xi_i \geq 0 \end{cases} \end{aligned} \quad (1)$$

其中, $\mathbf{w}$ 为权向量, b 为偏置项, C 是用于控制误差的惩罚常数, ξ_i 为非负松弛因子.

利用 Lagrange 乘子法可以把式(1)转化为其对偶形式^[1]:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i'=1}^n \alpha_{i'} - \frac{1}{2} \sum_{i,i'=1}^n \alpha_i \alpha_{i'} z_i z_{i'} (\mathbf{y}_i^d \cdot \mathbf{y}_{i'}^d) \\ \text{s.t.} \quad & \begin{cases} \sum_{i=1}^n \alpha_i z_i = 0 \\ \alpha_i \in [0, C] \end{cases} \end{aligned} \quad (2)$$

通过对上式进行求解, 得最优解 $\boldsymbol{\alpha}^* = (\alpha_1^*, \dots, \alpha_n^*)^T$. 选取 $\boldsymbol{\alpha}^*$ 的一个正分量 $0 < \alpha_i^* < C$, 并据此计算偏置项

$$b^* = z_{i'} - \sum_{i=1}^n z_i \alpha_i^* (\mathbf{y}_i^d \cdot \mathbf{y}_{i'}^d).$$

对未知类别的数据点 $\mathbf{y}_T^d$, 可以通过如下线性判别函数决定其所属类别:

$$f_d(\mathbf{y}_T^d) = \text{sgn} \left(\sum_{i=1}^n \alpha_i^* z_i (\mathbf{y}_i^d \cdot \mathbf{y}_T^d) + b^* \right) \quad (3)$$

对于非线性 SVM 的情况, 通过核函数 $K(\mathbf{y}_i^d, \mathbf{y}_T^d) = \phi(\mathbf{y}_i^d) \times \phi(\mathbf{y}_T^d)$ 将输入空间映射到高维特征空间, 即用核函数 $K(\mathbf{y}_i^d, \mathbf{y}_T^d)$ 代替线性 SVM 中的点积 $(\mathbf{y}_i^d \cdot \mathbf{y}_T^d)$ 形式.

2.4 算法步骤

综上所述, 基于随机子空间-正交局部保持投影的支持向量机分类算法可概括为:

训练阶段:

输入: 训练样本集 $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_n] \subset R^{M \times n}$ 及其类别标签 $\mathbf{Z} = [z_1, z_2, \dots, z_n]$.

输出: D 个 SVM 分类器 $\tilde{\varphi}^d(x)$, $d = 1, 2, \dots, D$.

步骤: For $d = 1, 2, \dots, D$

1. 按均匀分布采样方式, 从 M 维训练样本 $\mathbf{X}$ 中随机选择 p 维构成随机子空间 $\mathbf{X}^d$;

2. 利用 OLPP 算法对 $\mathbf{X}^d$ 进行特征提取生成新的训练样本 $\mathbf{Y}^d$;

3. 利用 $\mathbf{Y}^d$ 构造 SVM 分类器 $\tilde{\varphi}^d(x)$.

End

测试阶段:

输入: 测试样本 $\mathbf{X}_T = [\mathbf{x}_{T1}, \mathbf{x}_{T2}, \dots, \mathbf{x}_{Tn}] \subset R^{M \times n}$, SVM 分类器 $\tilde{\varphi}^d(x)$, 类别总数 c .

输出: 测试样本 $\mathbf{X}_T$ 的分类结果 $R(\mathbf{X}_T)$.

步骤: For $d = 1, 2, \dots, D$

1. 找出训练子空间样本 $\mathbf{X}^d$ 对应的测试样本 $\mathbf{X}_T$ 的子空间 $\mathbf{X}_T^d$;

2. 利用 OLPP 算法对 $\mathbf{X}_T^d$ 进行特征提取生成新的测试样本 $\mathbf{Y}_T^d$;

3. 利用 SVM 分类器 $\tilde{\varphi}^d(x)$ 对 $\mathbf{Y}_T^d$ 进行分

类, 获得 $f_d(\mathbf{y}_T^d)$.

End

利用贝叶斯求和规则融合分类结果 $f_d(\mathbf{y}_T^d)$, 得最终分类结果 $R(\mathbf{X}_T) = \arg\max_g [\sum_{d=1}^D P(g|d)]$, 其中 $g = 1, 2, \dots, c$, $P(g|d)$ 是一个测试样本在 d 分类器中属于 g 类的概率, 有 $P(g|d) = 1 / \{1 + \exp(-|f_d(\mathbf{y}_T^d)|)\}$.

3 实验结果与分析

分别选用 Yale 和 UMIST 人脸数据库进行实验分析, 并和标准支持向量机(SVM)、基于随机子空间的支持向量机(RS-SVM)及基于 OLPP 降维的支持向量机(OLPP-SVM)相比较. 为了比较的公平性, 这 4 种支持向量机的共有参数均设为一致, 如均选用高斯径向基核函数且核函数宽度均为 1, 惩罚因子 $C = 1$, OLPP 近邻数 $h = 5$. 仿真中, 每个实验均做 30 次, 取平均值. 计算机的硬件配置为: Pentium CPU 主频 2.20GHz, 内存 2GB, 采用 MATLAB7.8.0 软件编程.

3.1 Yale 人脸库及实验结果

Yale 数据库 (<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>) 是由耶鲁大学计算机视觉与控制中心创建的人脸图像库. 该数据库由 15 个人组成, 共 165 张灰度图像. 每个人含有不同光照、表情、姿态等变化共 11 张图像. 实验中, 图像的大小为 32×32 . 实验选取每个人的前 6 张图像用于训练, 剩下的 5 张图像构成测试集.

实验过程中, OLPP 特征维数 $m = 16$, 随机子空间个数 $D = 20$, 分析随机子空间维数对算法分类精度的影响, 图 1 给出了 RSOLPP-SVM 的分类精度与随机子空间维数的关系. 由图 1 可以看出, 当随机子空间维数为 150 时, 分类精度最高. 因此, 在接下来的实验中, 对于 Yale 人脸库, 选择随机子空间维数 $p = 150$.





图1 分类精度与随机子空间维数的关系(Yale人脸库)

保持随机子空间维数 $p = 150$ 不变, 分析随机子空间个数对 RSOLPP-SVM 分类性能的影响. 图 2 给出了 RSOLPP-SVM 的分类精度和分类时间随子空间个数的变化情况. 由图 2(a)可以看出, 随机子空间个数对算法的分类精度影响不大. 图 2(b)则表明: RSOLPP-SVM 的分类时间与随机子空间个数之间基本上成线性增长



(a) 分类精度与随机子空间个数关系 (b) 分类时间与随机子空间个数关系
图2 分类精度及分类时间与随机子空间个数的关系(Yale人脸库)关系。

表 1 给出了 4 种 SVM 在 Yale 人脸库上的分类性能比较及相关参数设置情况。

表 1 分类性能比较(Yale 人脸库)

SVM 类型	分类性能		参数设置				
	分类时间(s)	分类精度(%)	D	p	m	训练集	测试集
RSOLPP-SVM	2.4570	91.22	20	150	16	90	75
OLPP-SVM	0.1946	43.33	/	/	16	90	75
RS-SVM	0.3156	6.67	20	150	/	90	75
SVM	0.1051	6.67	/	/	/	90	75

3.2 UMIST 人脸库及实验结果

UMIST 人脸库 (<http://images.ee.umist.ac.uk/dan-ny/database.html>)是由英国曼彻斯特大学创建的,共包含 20 个人的 564 张人脸灰度图片.实验选用 UMIST 子库进行分析,该子库由 20 个人组成,前 14 个人有 25 张不同姿态的照片,后 6 人含有 15 张.图片大小为 112 × 92.

根据训练集和测试集的设置情况,UMIST 人脸库上的实验分为两组.第一组:训练集为前 14 个人各选 20 张图片,后 6 人各选 10 张图片,测试集则是每人剩下的 5 张图片(训练集和测试集分别为 340 和 100 张图片);第二组:分别选用每人前 5 张图片构成训练集,测试集是前 14 个人各选 20 张图片,后 6 人各选 10 张图片(训练集和测试集分别为 100 和 340 张图片).表 2 和 3 分别给出了这两组实验的分类性能比较及相关参数设置情况.

3.3 讨论

比较 Yale 和 UMIST 人脸库上的实验结果,可得到以下几点结论:

(1)在 Yale 和 UMIST 人脸库中,RSOLPP-SVM 的分类精度比 OLPP-SVM 和 SVM 的分类精度都要高.主要是由于 RSOLPP-SVM 利用了随机子空间的随机采样特性,使得各基 SVM 的训练样本之间既存在一定的差异性又具有一定的关联性,从而使得各基 SVM 分类器具有很好的互补性.

(2)在 Yale 和 UMIST 人脸库中,RSOLPP-SVM 的分类精度明显高于 RS-SVM 的分类精度.这主要是因为当

原始特征空间的样本存在很多冗余特征时,RSOLPP-SVM 通过 OLPP 降维可以有效地降低样本的冗余度,保留对识别有用的特征,从而使分类器具有更好的分类精度.

(3)与 OLPP-SVM、RS-SVM 和 SVM 相比,由于 RSOLPP-SVM 需要对多个随机子空间上的样本进行多次 OLPP 降维,因此 RSOLPP-SVM 需要花费更多的时间来进行人脸识别.也就是说,RSOLPP-SVM 能够在牺牲计算机耗时的情况下,使得分类精度大幅度提高,而且表 2 中 42.59 秒的最高分类时间还是可以接受的.

(4)表 2 和表 3 中的分类时间明显多于表 1 中的分类时间.这是由于与 Yale 人脸库相比,UMIST 人脸库中原始样本的维数及 OLPP 的特征维数均较高,因此需要花费较多时间来进行分类.

表 2 分类性能比较(UMIST 人脸库第一组)

SVM 类型	分类性能		参数设置				
	分类时间(s)	分类精度(%)	D	p	m	训练集	测试集
RSOLPP-SVM	42.59	98.91	20	500	20	340	100
OLPP-SVM	3.8149	40.88	/	/	20	340	100
RS-SVM	10.6674	5.0	20	500	/	340	100
SVM	10.5819	5.0	/	/	/	340	100

表 3 分类性能比较(UMIST 人脸库第二组)

SVM 类型	分类性能		参数设置				
	分类时间(s)	分类精度(%)	D	p	m	训练集	测试集
RSOLPP-SVM	39.6384	95.59	20	500	20	100	340
OLPP-SVM	3.5431	40	/	/	20	100	340
RS-SVM	2.7409	2.94	20	500	/	100	340
SVM	2.6793	2.94	/	/	/	100	340

(5)在 Yale 和 UMIST 人脸库中,RS-SVM 和 SVM 分类精度相同且为最低.这是因为原始特征空间的样本和随机子空间选择出来的样本中存在很多冗余特征,致使 SVM 分类器无法正确识别并将所有样本误判为同一类.

(6)由表 2 和表 3 可得:训练样本越多,RSOLPP-SVM 分类器的分类精度越高,分类时间也会增加.但能够在牺牲近 3 秒(约占总时间 7.5%)时间下,使分类精度提高 3 个百分点.在这种情况下,可以考虑增加训练样本个数,达到提高分类精度的效果.

4 结论

支持向量机是一种典型的核机器学习方法,已在模式识别、信号处理、最优控制、系统建模等领域得到了广泛的应用.但是在实际应用过程中,支持向量机通常面临两个方面的问题:高维数据易于导致的维数灾难,以及小样本造成的泛化性能下降.为此,将特征

提取以及集成学习技术引入支持向量机,提出一种基于随机子空间-正交局部保持投影的支持向量机 RSOLPP-SVM,其中随机子空间方法用于增强集成分类器之间的独立性和互补性,正交局部保持投影用于对各随机子空间的高维样本进行维数约简.在 Yale 和 UMIST 人脸库上的实验结果表明,与 OLPP-SVM、RS-SVM 和 SVM 相比,RSOLPP-SVM 能够有效地提高支持向量机的分类精度,适用于高维数、小样本的分类问题.

参考文献

- [1] 胡根生,梁栋,孔颖.基于支持向量值轮廓波变换的遥感影像融合[J].电子学报,2010,38(6):1287-1292.
Hu Gen-Sheng, Liang Dong, Kong Jie. Remote sensing image fusion based on support vector value contourlet transform[J]. Acta Electronica Sinica, 2010, 38(6): 1287-1292. (in Chinese)
- [2] Song X F, Chen W M, Chen Y P P, et al. Candidate working set strategy based SMO algorithm in support vector machine [J]. Information Processing and Management, 2009, 45(5): 584-592.
- [3] Babaoglu I, Findik O, Bayrak M. Effects of principle component analysis on assessment of coronary artery diseases using support vector machine[J]. Expert Systems with Applications, 2010, 37(3): 2182-2185.
- [4] Wang X S, Gu Y Y, Cheng Y H, et al. An ensemble classifier based on selective independent component analysis of DNA microarray data[J]. The Chinese Journal of Electronics, 2009, 18(4): 645-649.
- [5] 尹洪涛,付平,沙学军.基于 DCT 和线性判别分析的人脸识别[J].电子学报,2009,37(10):2211-2214.
Yin Hong-Tao, Fu Ping, Sha Xue-Jun. Face recognition based on DCT and LDA[J]. Acta Electronica Sinica, 2009, 37(10): 2211-2214. (in Chinese)
- [6] Meng Y F, Ren M Q, Cai J Y, et al. Research on radar emitters classification with fuzzy support vector machines[A]. Proceedings of the International Forum on Information Technology and Applications[C]. Piscataway: IEEE Inc Press, 2009: 161-164.
- [7] 应自炉,唐京海,李景文,等.支持向量鉴别分析及在人脸表情识别中的应用[J].电子学报,2008,36(4):725-730.


Ying Zi-Lu, Tang Jing-Hai, Li Jing-Wen, et al. Support vector discriminant analysis and its application to facial expression recognition[J]. Acta Electronica Sinica, 2008, 36(4): 725-730. (in Chinese)

- [8] He X F, Niyogi P. Locality preserving projections[A]. Proceedings of the Neural Information Processing Systems[C]. USA: The MIT Press, 2003. 153-160.
- [9] Cai D, He X F, Han L W, et al. Orthogonal laplacianfaces for face recognition[J]. IEEE Transactions on Image Processing, 2006, 15(11): 3608-3614.
- [10] Ho T K. The random subspace method for constructing decision forests[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20: 832-844.

作者简介



王雪松 女,1974 年生于安徽泗县,2002 年获中国矿业大学控制理论与控制工程专业博士学位,现为中国矿业大学信息与电气工程学院教授,博士生导师.主要研究方向为机器学习、复杂系统优化与控制、生物信息学等.
E-mail: wangxuesongcumt@163.com



高 阳 男,1985 年生于江苏连云港,2008 年获中国矿业大学学士学位,现为中国矿业大学控制理论与控制工程专业博士研究生,研究方向为核机器学习.
E-mail: gaojianrui88@163.com



程玉虎 男,1973 年生于安徽淮南,2005 年获中国科学院自动化研究所控制理论与控制工程专业博士学位,现为中国矿业大学信息与电气工程学院副教授.主要研究方向为机器学习和智能系统等.
E-mail: chengyuhu@163.com