

# 一种核正交鉴别保局投影算法

林玉娥, 顾国昌, 刘海波, 沈 晶

(哈尔滨工程大学计算机科学与技术学院, 黑龙江哈尔滨 150001)

**摘 要:** 正交鉴别保局投影算法是一种有效的特征提取方法,但是将其应用在人脸识别中将遇到小样本问题,并且算法只是一种线性的特征提取方法,因此提出一种核正交鉴别保局投影算法.实现这一算法的关键是高维特征空间中总体散布矩阵的非零空间的计算,对此根据 eigenfaces 中将高阶矩阵计算转化成低阶矩阵计算的思想及核函数技术,将高维特征空间中总体散布矩阵的非零空间的计算仍归结为标准的特征值分解问题,并且所提出的算法能够有效地解决小样本问题.在人脸库上的实验结果验证了所提出的算法是可行的和有效的.

**关键词:** 正交鉴别保局投影; 特征提取; 人脸识别; 总体散布矩阵; 核函数

**中图分类号:** TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2010) 04-0979-04

## A Kernel Orthogonal Discriminant Locality Preserving Projections Method

LIN Yu-e, GU Guo-chang, LIU Hai-bo, SHEN Jing

(School of Computer Science and Technology, Harbin Engineering University, Harbin, Heilongjiang 150001, China)

**Abstract:** Orthogonal discriminant locality preserving projections is an effective feature extraction, but it may encounter the small size samples problem when it is applied in face recognition task. In addition, it is only a linear feature extraction technique. A kernel orthogonal discriminant locality preserving projections is proposed. The key is to how to compute the nonzero space of the total scatter matrix in the higher dimensional feature space. As to this problem, the kernel function technique and the eigenfaces method that transforms the computation of the high order matrix into the computation of the low order matrix are used, and then the actual computation of the nonzero space of the total scatter matrix in the higher dimensional feature space is reduced to a standard eigenvalue problem. In addition, the proposed algorithm can effectively overcome small size samples problem. The numerical experiments on facial databases show that the proposed method is effective and feasible.

**Key words:** orthogonal discriminant locality preserving projections; feature extraction; face recognition; total scatter matrix; kernel function

## 1 引言

最近 He 等人提出的保局投影<sup>[1]</sup>(Locality Preserving Projections, LPP)算法在人脸识别领域取得了成功的应用,但是 LPP 所提取的特征向量之间存在着信息冗余,因此文献[2]进一步发展了 LPP,提出具有正交性的 LPP (Orthogonal Locality Preserving Projections, OLPP).然而 OLPP 未能充分利用样本的类别信息,当人脸图像的光照、姿态、表情发生较明显变化时,OLPP 的识别性能会明显下降.因此文献[3]提出了正交鉴别保局投影(Orthogonal Discriminant Locality Preserving Projections, ODLPP),其思想是考虑将类别信息加入目标函数中,从而进一步改善了算法的识别性能.

上述的 ODLPP 属于线性特征提取方法,因而最终获得的只是线性特征.另外 ODLPP 受小样本制约,据

此,本文首先给出了 ODLPP 解决小样本问题的方案,然后在此基础上结合核函数学习方法<sup>[4~8]</sup>的思想,提出了一种核正交鉴别保局投影(Kernel Orthogonal Discriminant Locality Preserving Projections, KODLPP)算法.算法首先将原始样本通过非线性映射隐式地映射到高维特征空间;然后在高维空间里建立了 KODLPP 的目标函数,在求解时,本文利用 eigenfaces<sup>[9]</sup>求解高阶协方差矩阵所采用的思想及核函数技术,将高维特征空间中的计算仍归结为标准的特征值分解问题,同时所提出的算法能够有效地解决小样本问题.

## 2 正交鉴别保局投影

假设在高维欧氏空间  $\mathbf{R}^D$  中有  $C = \{n_1, n_2, \dots, n_c\}$  个类别,每类有  $N_i$  个样本,  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$  为样本集,共有  $N$  个样本,每个样本属于  $C$  类中的某一类.在

人脸识别中,首先就是要找到一个投影矩阵  $\mathbf{W}$ ,该投影矩阵不但要使投影后的人脸图像具有较低的维数,而且也要具有较好的可分性。 $\mathbf{W}$ 是按照某种目标函数求得的最佳投影矩阵。

ODLPP的目标函数定义为

$$\min_{\mathbf{W}^T \mathbf{W} = \mathbf{I}} J(\mathbf{W}) = \frac{\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W})}{\text{tr}(\mathbf{W}^T \mathbf{S}_b \mathbf{W})} \quad (1)$$

上式中的  $\mathbf{S}_b$  为类间散布矩阵,  $\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W})$  可展开成

$$\text{tr}(\mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W}) = \sum_{i=1}^N \sum_{j=1}^N \| \mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j \|^2 s_{ij} \quad (2)$$

式(2)中的权值  $s_{ij}$ ,可按式(3)求出

$$s_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/t), & \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 属于同类样本} \\ 0, & \text{其他} \end{cases} \quad (3)$$

式(1)中的  $\mathbf{L} = \mathbf{D} - \mathbf{S}$  为拉普拉斯矩阵,  $\mathbf{S}$  是由  $s_{ij}$  构成,表示位置相似矩阵;  $\mathbf{D}$  为对角阵,其对角元素  $d_{ii} = \sum_j s_{ij}$ ;  $\epsilon$  代表一个较小的正数. ODLPP 目标函数的意义是在保持类内局部流形结构不变的同时,最大化类间散布矩阵,并保证所求得的鉴别矢量之间相互正交. 算法的具体求解及证明请参见文献[3].

### 3 关于 ODLPP 的奇异问题

首先来讨论一下 ODLPP 所存在的问题,而这也是实现本文的 KODLPP 的一个前提条件. ODLPP 在具体求解中,首先要对  $\mathbf{S}_b$  求逆,然而在人脸识别中,由于人脸样本维数远大于样本数目,存在着小样本问题,因此将使得  $\mathbf{S}_b$  奇异,此时并不能直接进行计算. 而对于这一问题文献[3]并没有给出具体的解决方法. 对此本文给出一种有效的解决方法,其思想类似于文献[10]的求解方法,即首先求出总体散布矩阵  $\mathbf{S}_t$  的非零特征值所对应的标准正交矢量,这些非零特征值所对应的标准正交矢量就构成了  $\mathbf{S}_t$  的非零空间  $\mathbf{V}$ ,然后将  $\mathbf{S}_b$  投影到  $\mathbf{V}$  上得到  $\tilde{\mathbf{S}}_b$ ,再对  $\tilde{\mathbf{S}}_b$  进行特征值的分解,求出  $\tilde{\mathbf{S}}_b$  的非零空间  $\mathbf{U}$ ,再将  $\tilde{\mathbf{S}}_b$  投影到  $\mathbf{U}$  上得到  $\bar{\mathbf{S}}_b$ ,此时的  $\bar{\mathbf{S}}_b$  非奇异,即可按 ODLPP 进行计算.

## 4 核正交保局投影

### 4.1 KODLPP 的基本原理

KODLPP 的基本思想是:首先将原始训练样本通过一个非线性映射  $\Phi$  变换到某一高维(可能是无限维)特征空间  $\mathbf{H}$  中,然后在高维特征空间  $\mathbf{H}$  中应用 ODLPP 求出正交保局鉴别矢量集. 则经过非线性映射  $\Phi$  后,  $\mathbf{X}$  在高维特征空间  $\mathbf{H}$  中的表示为

$$\Phi(\mathbf{X}) = [\Phi(\mathbf{x}_1) \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_N)] \quad (4)$$

式(4)中  $\Phi(\mathbf{x}_i) \in \mathbf{H}$ , 是  $\mathbf{x}_i$  所对应的高维空间  $\mathbf{H}$  中的样本矢量. 为了方便下文的推导,首先给出  $\mathbf{H}$  中的类间散布矩阵  $\mathbf{S}_b^\Phi$  和总体散布矩阵  $\mathbf{S}_t^\Phi$  的定义<sup>[11]</sup>

$$\mathbf{S}_b^\Phi = \Phi(\mathbf{X})(\mathbf{L} - \mathbf{M})(\mathbf{L} - \mathbf{M})^T(\Phi(\mathbf{X}))^T = \mathbf{B}\mathbf{B}^T \quad (5)$$

$$\mathbf{S}_t^\Phi = \Phi(\mathbf{X})(\mathbf{I} - \mathbf{M})(\mathbf{I} - \mathbf{M})^T(\Phi(\mathbf{X}))^T = \mathbf{T}\mathbf{T}^T \quad (6)$$

式中  $\mathbf{I}$  是  $N \times N$  的单位阵,  $\mathbf{L} = (\mathbf{L}_l)_{l=1, \dots, c}$  是  $N \times N$  的块对角阵,其中每个对角块  $\mathbf{L}_l$  所有元素均为  $1/N_l$ , 大小为  $N_l \times N_l$  的矩阵,式中  $\mathbf{M}$  为大小为  $N \times N$  的矩阵,该矩阵的所有元素均为  $1/N$ . 则在  $\mathbf{H}$  中,关于 KODLPP 的目标函数为

$$\min_{\mathbf{W}^T \mathbf{W} = \mathbf{I}} J^\Phi(\mathbf{W}) = \frac{\text{tr}(\mathbf{W}^T(\Phi(\mathbf{X}))\mathbf{L}(\Phi(\mathbf{X}))^T\mathbf{W})}{\text{tr}(\mathbf{W}^T\mathbf{S}_b^\Phi\mathbf{W})} \quad (7)$$

根据第3节的讨论,可知首先要求出总体散布矩阵  $\mathbf{S}_t^\Phi$  的非零空间  $\mathbf{V}^\Phi$ ,然而由于非线性映射  $\Phi$  未知,因此无法在特征空间  $\mathbf{H}$  中直接进行特征值分解计算出  $\mathbf{S}_t^\Phi$  的各个标准正交矢量. 已有的核方法均采用假设所求取的鉴别矢量是由高维空间样本线性生成,不同于此,本文提出一种新的求解方法,由文献[9]所提出 eigenfaces 方法可知,该方法在计算高维数据的总体散布矩阵时,使用了对称矩阵的一个性质,即  $\mathbf{T}\mathbf{T}^T$  与  $\mathbf{T}^T\mathbf{T}$  具有相同的特征值,从而可将高阶矩阵的求解转化成为低阶矩阵的求解,因此本文将 eigenfaces 的求解思想用到 KODLPP 中,下面将对这一求解方法进行推导.

### 4.2 KODLPP 的具体推导及实现

根据  $\mathbf{T}\mathbf{T}^T$  所对应的特征值与  $\mathbf{T}^T\mathbf{T}$  的特征值相同,所以首先来求  $\mathbf{T}^T\mathbf{T}$  的特征值与特征向量,即

$$\begin{aligned} \mathbf{T}^T\mathbf{T} &= (\mathbf{I} - \mathbf{M})^T\Phi(\mathbf{X})^T\Phi(\mathbf{X})(\mathbf{I} - \mathbf{M}) \\ &= (\mathbf{I} - \mathbf{M})^T\mathbf{K}(\mathbf{I} - \mathbf{M}) \end{aligned} \quad (8)$$

式(8)中的  $\mathbf{K} = \Phi(\mathbf{X})^T\Phi(\mathbf{X})$  即为核矩阵,它是由映射后样本的内积运算生成,此时即可利用 SVM 中的核函数技术进行有效的计算. 对式(8)进行变换可得

$$\begin{aligned} \mathbf{T}^T\mathbf{T}\mathbf{U} &= \mathbf{\Sigma}\mathbf{U} \\ \mathbf{T}\mathbf{T}^T\mathbf{T}\mathbf{U} &= \mathbf{T}\mathbf{\Sigma}\mathbf{U} \\ \mathbf{S}_t^\Phi(\mathbf{T}\mathbf{U}) &= \mathbf{\Sigma}(\mathbf{T}\mathbf{U}) \end{aligned} \quad (9)$$

式(9)中  $\mathbf{\Sigma} = \begin{pmatrix} \mathbf{\Sigma}_m^2 & 0 \\ 0 & 0 \end{pmatrix}$ ,  $\mathbf{\Sigma}_m^2$  是  $\mathbf{T}^T\mathbf{T}$  的非零特征值按降序排列的对角阵,  $m = \text{rank}(\mathbf{T}^T\mathbf{T})$ ,  $\mathbf{U}$  是  $\mathbf{T}^T\mathbf{T}$  的特征向量组成的矩阵,令  $\mathbf{U} = (\mathbf{U}_1, \mathbf{U}_2)$ ,  $\mathbf{U}_1 \in \mathbf{R}^{N \times m}$ ,  $\mathbf{U}_2 \in \mathbf{R}^{N \times (N-m)}$ ,  $\mathbf{U}_1$  为  $\mathbf{T}^T\mathbf{T}$  的所有非零特征值所对应的特征向量,则可知  $\mathbf{P} = \mathbf{T}\mathbf{U}_1 = \Phi(\mathbf{X})(\mathbf{I} - \mathbf{M})\mathbf{U}_1$  即是  $\mathbf{S}_t^\Phi$  所有非零特征值所对应特征向量,此时要对  $\mathbf{T}\mathbf{U}_1$  进行归一化,以保证  $\mathbf{T}\mathbf{U}_1$  为  $\mathbf{S}_t^\Phi$  的标准正交向量集,令  $\mathbf{P} = \mathbf{T}\mathbf{U}_1\mathbf{\Sigma}_m^{-1}$  ( $\mathbf{\Sigma}_m$  对角线上的值均为正值),则有  $(\mathbf{P})^T\mathbf{P} = (\mathbf{T}\mathbf{U}_1\mathbf{\Sigma}_m^{-1})^T(\mathbf{T}\mathbf{U}_1\mathbf{\Sigma}_m^{-1}) = \mathbf{\Sigma}_m^{-1}\mathbf{U}_1^T\mathbf{T}^T\mathbf{T}\mathbf{U}_1\mathbf{\Sigma}_m^{-1}$

$$= \Sigma_m^{-1} (U_1^T T^T T U_1) \Sigma_m^{-1} = I \quad (10)$$

因此可知  $P$  即是  $S_i^\Phi$  的非零空间  $V_i^\Phi$ . 则此时 KODLPP 的目标函数可转换为

$$\min_{W^T W = I} J^\Phi(W) = \frac{\text{tr}(W^T (\Phi_V(X)) L (\Phi_V(X))^T W)}{\text{tr}(W^T \bar{S}_b^\Phi W)} \quad (11)$$

式(11)中的  $\Phi_V(X)$  和  $\bar{S}_b^\Phi$  分别为

$$\begin{aligned} \Phi_V(X) &= \Sigma_m^{-1} U_1^T (I - M)^T K \\ \bar{S}_b^\Phi &= (V_t^\Phi)^T S_b^\Phi (V_t^\Phi) = (TU_1 \Sigma_m^{-1})^T S_b^\Phi (TU_1 \Sigma_m^{-1}) \\ &= (\Sigma_m^{-1} U_1^T T^T) B B^T (TU_1 \Sigma_m^{-1}) \\ &= \Sigma_m^{-1} U_1^T (I - M)^T K (L - M) (L - M)^T K (I - M) \\ &\quad \cdot U_1^T \Sigma_m^{-1} \end{aligned} \quad (12)$$

则可知经过投影变换后, KODLPP 的目标函数不含有任何未知量, 但是并不能保证  $\bar{S}_b^\Phi$  非奇异, 故要再次对  $\bar{S}_b^\Phi$  进行特征分解, 求出  $\bar{S}_b^\Phi$  非零空间  $U^\Phi$ . 由于  $\bar{S}_b^\Phi$  不含有任何未知量, 可直接对其对行特征值分解, 求出其非零空间  $U^\Phi$ . 对目标函数再次进行投影变换, 则式(11)可转换为

$$\min_{W^T W = I} J^\Phi(W) = \frac{\text{tr}(W^T (\Phi_{VU}(X)) L (\Phi_{VU}(X))^T W)}{\text{tr}(W^T \bar{S}_b^\Phi W)} \quad (13)$$

显然  $\bar{S}_b^\Phi$  非奇异, 故可直接应用 ODLPP 方法进行求解, 因此 KODLPP 的具体求解步骤如下:

- (1) 首先计算核矩阵  $K$ ;
- (2) 求出式(8)中所有非零特征值及所对应的特征向量, 即  $\Sigma_m$  和  $U_1$ , 此时设  $S_i^\Phi$  的非零空间为  $V_i^\Phi = P = TU_1 \Sigma_m^{-1}$ ;
- (3) 按式(12)将  $S_b^\Phi$  投影至  $V_t^\Phi$  上得到  $\bar{S}_b^\Phi$ , 同时求出  $\Phi_V(X)$ , 然后对  $\bar{S}_b^\Phi$  进行特征分解, 求出  $\bar{S}_b^\Phi$  的非零空间  $U^\Phi$ ;
- (4) 再次将  $\Phi_V(X)$  和  $\bar{S}_b^\Phi$  投影到  $U^\Phi$  上, 得到  $\Phi_{VU}(X)$  和  $\bar{S}_b^\Phi$ ;
- (5) 对式(13)先求出下面广义线性方程特征值与特征向量

$$\Phi_{VU}(X) L (\Phi_{VU}(X))^T b_i = \lambda_i \bar{S}_b^\Phi b_i$$

- (6) 选择对应前  $d$  个最小特征值所对应的特征向量  $b_1, b_2, \dots, b_d$ , 然后对  $b_1, b_2, \dots, b_d$  进行 Gram-Schmidt 正交化得到  $B$ , 则最终所求得的核正交保局鉴别矢量集为  $W = TU_1 \Sigma_m^{-1} U^\Phi B$ .

根据上面的求解过程, 则有如下定理 1.

**定理 1**  $W$  即是满足 KODLPP 目标函数式(7)的正交鉴别矢量集.

**证明** 由于  $W = TU_1 \Sigma_m^{-1} U^\Phi B$ , 故知

$$\begin{aligned} W^T W &= (TU_1 \Sigma_m^{-1} U^\Phi B)^T (TU_1 \Sigma_m^{-1} U^\Phi B) \\ &= (U^\Phi B)^T (TU_1 \Sigma_m^{-1})^T (TU_1 \Sigma_m^{-1}) (U^\Phi B) \\ &= (U^\Phi B)^T [(TU_1 \Sigma_m^{-1})^T (TU_1 \Sigma_m^{-1})] (U^\Phi B) \end{aligned}$$

根据式(10), 则  $W^T W$  可化简为

$$W^T W = (BU^\Phi)^T (U^\Phi B) = B^T (U^\Phi)^T U^\Phi B$$

$$= B^T [(U^\Phi)^T U^\Phi] B = B^T B = I \quad \text{证毕.}$$

因此根据定理 1, 可知本文利用 eigenfaces 方法求出的鉴别矢量集即是 KODLPP 所求的正交鉴别矢量集.

## 5 实验

为了验证本文提出算法的性能, 分别在 ORL 和 YALE 人脸库上进行了实验, 采用最近邻分类器进行分类. ORL 人脸库有 40 个人, 每人 10 幅图像, 图像尺寸为  $112 \times 92$  pixels; YALE 人脸库中包含 15 个人, 每人 11 幅图像, 图像尺寸为  $100 \times 100$  pixels. 实验中 KODLPP 采用了高斯核函数  $k(x, y) = \exp(-\|x - y\|^2 / \sigma)$ . 为了直观比较 ODLPP 和 KODLPP 的性能, 在两个人脸库上, 分别取每类的前 4 幅作为训练样本, 剩余图像为测试样本, 对两种方法所提取特征个数变化时的识别性能进行了比较, 结果如图 1 和 2 所示.

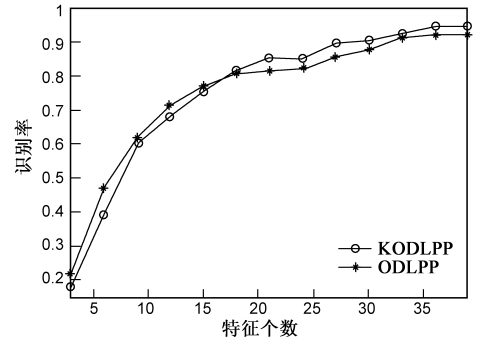


图1 ORL人脸库上2种方法的性能比较




图2 YALE人脸库上2种方法的性能比较

从以上两图可看出随着 KODLPP 选取特征个数增多时, 其识别率逐渐高于 ODLPP 的识别率, 特别是在光照变化较强的 YALE 人脸库上, 更能体现本文算法的优势.

为进一步测试本文算法, 消除偶然性, 在每次实验中每人分别随机选取 3~6 幅图像作为训练样本, 其余图像用于测试. 对 KODLPP、ODLPP 及两种经典的核方法 KPCA 和 KLDA 进行测试比较. 每组实验重复进行 10 次, 取平均值作为识别结果, 实验结果如表 1 和表 2 所示. 另外本文也对 KODLPP、ODLPP 的识别时间进行了比较, 如表 3 所示.

表1 ORL人脸库上的识别结果比较

算法名称	样本数目及正确识别率%			
	3	4	5	6
KPCA	89.32	91.20	93.25	95.32
KLDA	89.27	92.67	94.10	96.00
ODLPP	89.61	91.75	94.10	95.75
KODLPP	90.75	93.33	95.35	97.12

表2 YALE人脸库上的识别结果比较

算法名称	样本数目及正确识别率%			
	3	4	5	6
KPCA	79.25	83.43	86.67	88.80
KLDA	81.58	83.73	89.11	90.67
ODLPP	81.33	84.32	88.63	90.18
KODLPP	82.83	85.56	90.15	91.73

表3 2种方法识别的时间比较(时间:s)

人脸库/鉴别矢量个数	ODLPP	KODLPP
YALE/14	2.325	3.538
ORL/39	8.437	11.256

从表1和表2的结果可以看出, KODLPP明显优于线性的ODLPP, 这说明经过非线性变换后, 确实可以提高算法的识别性能, 而且也优于两种经典的核方法KLDA和KPCA. 但从表3可以看出KODLPP的识别时间较ODLPP有所增加, 然而从提高识别率的角度考虑, 增加少量的时间也是值得的.

为了进一步验证本文算法的识别性能, 采用了人脸姿态、表情等变化较大的FERET大型人脸图库<sup>[12]</sup>(该库是由美国国防部建立的, 现已成为国际上通用的对人脸识别算法进行评估的一个标准数据库), 选择其一个子集来进行测试. 该子集包括200人, 每人7张图片. 在实验中, 每幅原始图像中人脸部分是根据眼睛的位置获取, 获取的人脸部分尺寸为 $80 \times 80$ pixels. 在本次实验中, 随机选取每类的5幅作为训练样本, 剩余图像为测试样本, 对四种方法进行了10次测试, 识别结果如图3所示. 从图3的10次测试结果可以看出, KODLPP明显优于ODLPP和KPCA, 同时也优于KLDA的识别结果, 这也说明即使在变化较大的大型人脸库上, KODLPP仍然具有较好识别性能.





图3 FERET人脸库上4种方法的识别结果比较

## 6 结论

进一步完善与发展了原有的ODLPP, 提出KODLPP. KODLPP综合了核技术和ODLPP的优点, 利用它来提取原始样本的特征, 一方面能够使得高度复杂和非线性的原始样本线性化和简单化, 另一方面本文的求解方法保证鉴别矢量集之间的正交性, 从而能够消除样本特征之间的信息冗余. 为基于核映射的特征提取方法提供了一种新的求解思路. 然而通过非线性变换后, 将使得ODLPP的计算时间有所增加, 因此如何减少KODLPP的计算量将是下一步要研究的问题.

### 作者简介:



林玉娥 女, 1979年3月出生于黑龙江省宁安, 现为哈尔滨工程大学计算机科学与技术学院在读博士研究生. 主要研究方向: 模式识别及图像处理. E-mail: linyu\_e@126.com



顾国昌 男, 1946生于4月出生于上海, 教授, 博士生导师. 主要研究方向: 模式识别、人工智能、智能控制及智能机器人等.

### 参考文献:

- [1] He X F, Yan S C, Hu Y, et al. Face recognition using Laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328 - 340.
- [2] Cai D, He X F, Han J W. Orthogonal laplacianfaces for face recognition[J]. IEEE Transactions on Image Process. 2006, 15(11): 3608 - 3614.
- [3] Zhu L, Zhu S N. Face recognition based on orthogonal discriminant locality preserving projections[J]. Neurocomputing, 2007, 70(9): 1543 - 1546.
- [4] Scholkopf B, Smola A. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computer, 1998, 10(5): 1299 - 1319.
- [5] Baudat G, Anouar F. Generalized discriminant analysis using a kernel approach[J]. Neural Computer, 2000, 12(10): 2385 - 2404.
- [6] Yang J, Jin Z, Yang J Y. Essence of kernel Fisher discriminant: KPCA plus LDA [J]. Pattern Recognition, 2004, 37(10): 2097 - 2100.

(下转第965页)

---

(上接第 982 页)

[7] 薛建中, 闫相国, 郑崇勋. 用核学习算法的意识任务特征提取与分类[J]. 电子学报, 2004, 32(10): 1749 - 1751.

Xue Jianzhong, Yan Xiangguo, Zheng Chongxu. Classifications of EEG during Mental Tasks by Kernel Learning Algorithms [J]. Acta Electronica Sinica, 2004, 32(10): 1749 - 1751. (in Chinese)

[8] 庞彦伟, 俞能海, 沈道义, 刘政凯. 基于核邻域保持投影的人脸识别[J]. 电子学报, 2006, 34(8): 1542 - 1544.

Pang Yanwei, Yu Nenghai, Shen Daoyi. Kernel neighborhood preserving projections for face recognition [J]. Acta Electronica Sinica, 2006, 34(8): 1542 - 1544. (in Chinese)

[9] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of

cognitive Neuroscience, 1991, 3(1): 71 - 86.

[10] Swets D L, Weng J Y. Using discriminant eigenfeatures for image retrieval [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(8): 831 - 836.

[11] Zheng W M, Zhao L. Foley-Sammon optimal discriminant vectors using kernel approach [J]. IEEE Transactions on neural networks, 2005, 16(1): 1 - 9.

[12] Phillips P J, Moon H, Rizvi S A, et al. The FERET Evaluation Methodology for face-Recognition Algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(10): 1090 - 1104.