一种基于局部排序 PCA 的线性鉴别算法

庞 成 郭志波 董 健

(扬州大学信息工程学院 扬州 225002)

摘 要 主分量分析(Principal Component Analysis, PCA)是模式识别领域中一种重要的特征抽取方法,该方法通过 K-L展开式来抽取样本的主要特征。基于此,提出一种拓展的 PCA 人脸识别方法,即分块排序 PCA 人脸识别方法 (MSPCA)。分块排序 PCA 方法先对图像矩阵进行分块,对所有分块得到的子图像矩阵利用 PCA 方法求出矩阵的所 有特征值所对应的特征向量并加以标识;然后找出这些所有的特征值中 & 个最大的特征值所对应的特征向量,用这些特征向量分别去抽取所属的子图像的特征;最后,在 MSPCA 的基础上,将抽取子图像所得到的特征矩阵合并,把这个合并后的特征矩阵作为新的样本进行 PCA+LDA。与 PCA 和 PCA+LDA 方法相比,分块排序 PCA 由于使用子图像矩阵,可以避免使用奇异值分解理论,从而更加简便。在 ORL 人脸库上的实验结果表明,所提出的方法在识别性能上明显优于经典的 PCA 和 PCA+LDA 方法。

关键调 主成分分析,特征抽取,分块 PCA,线性鉴别分析

中图法分类号 TP391.41

文献标识码 A

DOI 10. 11896/j. issn. 1002-137X, 2015, 8, 012

PCA Face Recognition Algorithm Based on Local Feature

PANG Cheng GUO Zhi-bo DONG Jian

(College of Information Engineering, Yangzhou University, Yangzhou 225002, China)

Abstract Principal component analysis is an important feature extraction method of pattern recognition, and the main features of the method are extracted from the sample by KL expansion. Therefore, we proposed a method of face recognition PCA expansion, called modular sorting PCA face recognition method (MSPCA). MSPCA method first divides the image matrix into blocks. The feature vectors, corresponded to all the feature value, are obtained from the sub-image matrix of all sub blocks by using PCA method, and the feature vectors are identified. Then the method finds out the feature vectors, corresponded to k maximum feature value of all eigenvalues. These feature vectors are taken to extract the characteristic of sub-image. Finally, based on the MSPCA, the feature matrix extracted from sub-images is merged, and then the combined feature matrix is as a new sample to implement PCA+LDA. Compared with the PCA method and PCA+LDA method, because of the use of sub-image matrix, MSPCA avoids using singular value decomposition theory, which makes it easier. Experimental results on ORL face database show that the proposed method outperforms the classical identification PCA and PCA+LDA methods.

Keywords Principal component analysis, Feature extraction, Modular PCA, LDA

1 引言

人脸识别是模式识别研究领域的重要课题,也是一个目前非常活跃的研究方向。在人脸图像识别中,主成分分析(Principal Component Analysis, PCA)又称 K-L 变换^[1,2],被认为是最成功的线性鉴别分析方法之一,目前仍然被广泛地应用于人脸等图像识别领域。本质上,PCA 方法的目的是在最小均方意义下寻找最能代表原始数据的投影。20世纪90年代初,Kirby和Sirovich等人讨论了利用PCA进行人脸图像的最优表示^[3]。接着,Turk和Pentland探讨了这种表示的物理意义并揭示了 K-L 展开表示人脸的本质^[46],他们通过K-L 变换也即主分量分析得到特征向量,当这些特征向量在

还原成图像矩阵时,都是标准化的人脸图像,即用一系列标准的人脸图像通过加权叠加来表示人脸,用这些表示系数作为人脸的特征进行分类识别。这些人脸图像都由于是由特征向量构成,故被形象地称为特征脸。特征脸方法就是将包含人脸的图像区域看作是一随机向量,可采用 K-L 变换获得其正交 K-L 基。对应其中较大特征值的基具有与人脸相似的形状,因此又称为特征脸。利用这些基底的线性组合可以描述、表达和逼近人脸图像,因此可以进行人脸识别和合成。识别过程就是将人脸图像投影到由特征脸张成的子空间上,比较其与已知人脸在特征空间中的位置。上述方法都是基于图像矩阵向量化这一方法,即这些方法在识别前都要将图像矩阵转化成图像向量,然后进行线性鉴别分析。但是由于转化成

到稿日期:2014-05-16 返修日期:2014-07-09 本文受扬州科技攻关项目(YZ2011099)资助。

庞 成(1989-),男,硕士生,主要研究方向为模式识别、机器视觉等,E-mail; pangcheng4432@126. com; **郭志波**(1975-),男,副教授,硕士生导师,主要研究方向为模式识别、机器视觉等,E-mail; zhibo_guo@163. com(通信作者);**董 儘**(1988-),男,硕士生,主要研究方向为数字图像处理、目标检测与跟踪等。

的图像向量的维数明显高于图像矩阵,人为地增加了进行线性鉴别的原始特征的维数,使得鉴别变得更加困难。以 ORL标准图像为例,一幅分辨率为 92×112 的图像对应的图像向量的维数高达 10304。这就使得鉴别时很容易遇到各种问题,比如常见的小样本问题、鉴别时间过长、硬件条件无法满足等等。对于出现的这些问题,人们相继提出了一些方法来解决,比如从样本本身人手,通过降低样本的图像向量的维数来消除奇异性[7,10];又有一些学者提出从算法人手,通过研究针对小样本问题的算法来解决这些问题[8,9,11,12]。

本文依据主成分分析的思想,提出一种 MSPCA 算法,原始样本经过 MSPCA 后再进行 PCA+LDA,得到最后结果。该算法从样本本身出发,在模式识别之前对原始图像样本进行分块[13,14],对分块得到的图像进行 PCA,从而得到所有分块样本的特征值和对应的特征向量。然后对这些特制值进行降序排序,找出最大的 k 个特征值和其所对应的特征向量,用这 k 个特征 矩阵 合并,用作新的训练样本进行 PCA+LDA。这种方法实际上是将原始的 PCA 方法的抽取全局特征变成了先通过分块 PCA 抽取局部特征,而且是经过了特征排序后的局部特征,然后将特征抽取所得到的特征矩阵作为新的训练样本进行 PCA+LDA。在 ORL 人脸库上的实验表明,该算法具有鲁棒性,识别率可以达到 95.12%。

2 LDA 方法与最优投影矩阵

经典的 LDA 采用的是 Fisher 判别准则函数,因此也称为 FLD。它最早由 Fisher 在 1936 年提出,基本思想是寻找使 Fisher 准则达到极大值的向量作为最佳投影方向,使投影后的样本能达到最大的类间离散度和最小的类内离散度,使投影后的样本具有最佳的可分离性。这是一种有效的用于分类的特征提取方法。

2.1 LDA 方法

设训练样本集 $\{x_i^{(j)}\}$ 中的样本分别属于 c 个模式类别: $\omega_1,\omega_2,\cdots,\omega_r$,其中 $i=1,2,\cdots,c,j=1,2,\cdots,n_i$,其中 n_i 表示第 i 类样本的数目, $x_i^{(j)}$ 表示该样本是第 i 类中第 j 个样本,所有样本都为 m 维列向量,则类内散布矩阵 S_w 、类间散布矩阵 S_b 与总体散布矩阵 S_c 分别定义为:

$$S_{w} = \sum_{i=1}^{L} P(\omega_{i}) \frac{1}{n_{i}} \sum_{i=1}^{n_{i}} (x_{i}^{(j)} - \overline{x}_{i}) (x_{i}^{(j)} - \overline{x}_{i})^{T}$$
 (1)

$$S_b = \sum_{i=1}^{c} P(\omega_i) (\overline{x}_i - \overline{x}) (\overline{x}_i - \overline{x})^{\mathrm{T}}$$
 (2)

$$S_{t} = \sum_{i=1}^{c} P(\omega_{i}) \frac{1}{n_{i}} \sum_{j=1}^{n_{i}} (x_{i}^{(j)} - \overline{x}) (x_{i}^{(j)} - \overline{x})^{T}$$
(3)

其中, $P(\omega_i)$ 为第 i 类的先验概率, $\bar{x}_i = E(x|\omega_i) = \frac{1}{n_i} \sum_{j=1}^{n_i} x_i^{(j)}$ 为 第 i 类中所有样本的均值向量, $\bar{x} = E(x) = \sum_{i=1}^{c} P(\omega_i) \bar{x}_i$ 为所有样本的期望中心向量,一般取 $P(\omega_i) = \frac{n_i}{N}$,此时 $\bar{x} = \frac{1}{N} \sum_{i=1}^{c} \sum_{j=1}^{n_i} x_i^{(j)}$ 为所有样本的均值向量。由式(1)一式(3) 的定义可知, S_w , S_b , S_b , S_b , S_b , S_b 为非负定矩阵,而且满足 $S_i = S_b + S_w$ 。

基于以上定义, Fisher 鉴别准则函数定义为:

$$J_f(\varphi) = \frac{\varphi^T S_b \varphi}{\varphi^T S_w \varphi} \tag{4}$$

最优投影方向选取使得准则函数 $J_f(\varphi)$ 达到最大值的向量 φ_{opt} 作为投影方向。事实上, 经典的 Fisher 线性鉴别分析的最优投影轴,即 A_{opt} 中的列向量 a_1, a_2, \cdots, a_d 一般取为广

义特征方程 $S_bA = \lambda S_wA$ 的 d 个最大的特征值所对应的特征 向量。即 a_1, a_2, \dots, a_d 满足以下条件:

2.2 特征抽取和识别

最优投影向量组 a_1, a_2, \dots, a_d 可用于特征抽取。对已知的样本图像向量 $M, \diamondsuit Y = a^T M,$ 其中 $a = (a_1, a_2, \dots, a_d)$ 。

对于测试样本 B、训练样本 A,计算:

 $d(A_i, B_j) = \|A_i - B_j\|_2 = [(A_i - B_j)^T (A_i - B_j)]^{\frac{1}{2}}, i = 1, 2, \cdots, c,$ 如果 $d(A_k, B_j) = \min d(A_i, B_j)$,那么测试样本 B_j 属于第 k 个样本。

本文采用 Fisherfaces 方法(PCA+LDA)解决 LDA 的高维小样本问题。首先采用 PCA 方法将高维的图像向量空间压缩到 N-c 维的特征空间,然后在降维后的空间中采用经典的 Fisher 线性鉴别分析方法将维数压缩为 d 维。

3 分块 PCA 方法

3.1 思想方法和投影矩阵

分块 PCA(MPCA)的思想是先将一个 $m \times n$ 的图像矩阵 M 分成 $p \times q$ 个分块的分块图像矩阵,即

$$M = egin{bmatrix} M_{11} & M_{12} & \cdots & M_{1q} \ M_{21} & M_{22} & \cdots & M_{2q} \ \cdots & \cdots & \cdots & \cdots \ M_{p1} & M_{p2} & \cdots & M_{pq} \ \end{pmatrix}$$

其中, $M \in R^{m \times n}$, $M_{ij} \in R^{m_1 \times n_1} (m_1 \times p = m, n_1 \times q = n)$ 。

设训练样本集中的样本分别属于 c 个模式类别: ω_1 , ω_2 , \cdots , ω_n ,第 i 类中有训练样本图像矩阵 $n_i \times p \times q$ 个,训练样本总数为 $N = \sum_{i=1}^{c} n_i \times p \times q$ 。基于以上定义,令 $(x_{ij})_{kl} = Vec(M_{ij})_{kl}$, $k=1,\cdots,p$, $l=1,\cdots,q$, $(x_{ij})_{kl} \in R^{m_1 \times n_1}$ 。于是所有训练图像样本的子图像矩阵的总体散布矩阵为:

$$S_{t} = \frac{1}{G} \sum_{i=1}^{c} \sum_{j=1}^{n_{i}} \sum_{k=1}^{p} \sum_{j=1}^{q} ((x_{ij})_{kl} - \overline{x})((x_{ij})_{kl} - \overline{x})^{T}$$
 (6)

其中, $G=(\sum_{i=1}^{L}n_i)p_q=Np_q$ 为所有训练样本子图像数目, $(x_{ij})_k$ 为第 kl 个子块中第 i 类训练样本中第 j 个样本的图像向量,x 为所有训练样本子图像向量均值。容易证明 S_i 为非负定矩阵。定义准则函数:

$$J_{(X)} = X^{\mathsf{T}} S_t X \tag{7}$$

然后我们在满足准则函数最大条件下需要寻找一组满足标准正交的最优投影向量组 a_1, a_2, \dots, a_r 。令 $P = [a_1, a_2, \dots, a_r]$ 为最优投影矩阵。

3.2 特征抽取

最优投影矩阵 $P=[a_1,a_2,\cdots,a_r]$ 用于特征抽取。得到 训练样本 M_{ij} 的特征矩阵为:

$$N_{ij} = \begin{pmatrix} (M_{ij})_{11}P & (M_{ij})_{12}P & \cdots & (M_{ij})_{1q}P \\ (M_{ij})_{21}P & (M_{ij})_{22}P & \cdots & (M_{ij})_{2q}P \\ \cdots & \cdots & \cdots \\ (M_{ij})_{p1}P & (M_{ij})_{p2}P & \cdots & (M_{ij})_{pp}P \end{pmatrix}$$

4 本文方法

4.1 分块排序 PCA 方法

分块排序 PCA 的思想是先将一个 $m \times n$ 的图像矩阵 M 分成 $p \times q$ 个分块的分块图像矩阵,即

$$M = egin{cases} M_{11} & M_{12} & \cdots & M_{1q} \ M_{21} & M_{22} & \cdots & M_{2q} \ \cdots & \cdots & \cdots & \cdots \ M_{p_1} & M_{p_2} & \cdots & M_{p_q} \ \end{cases}$$

其中, $M \in R^{m \times n}$, $M_{ij} \in R^{m_1 \times n_1}$ $(m_1 \times p = m, n_1 \times q = n)$.

我们对分块后的训练样本子图像按照所属分块分别实施 PCA 方法(即做 $k \times l$ 次 PCA)。

设训练样本集中的样本分别属于 c 个模式类别: ω_1 , ω_2 , \cdots , ω_i ,第 i 类中有训练样本子图像矩阵 $n_i \times p \times q$ 个,一个子块分类中第 i 类中有训练样本数目 n_i 个,一个子块类别中训练样本数目为 $N=\sum\limits_{i=1}^{c}n_i$ 。基于以上定义,令 $(x_{ij})_k=Vec(M_{ij})_k$, $k=1,\cdots,p$, $l=1,\cdots,q$, $(x_{ij})_k\in R^{m_1\times n_1}$ 。于是每个子块中所有训练图像样本子图像矩阵的总体散布矩阵为:

$$S_{t} = \frac{1}{N} \sum_{i=1}^{r_{t}} \sum_{j=1}^{n_{t}} ((x_{ij})_{kl} - \overline{x}_{kl}) ((x_{ij})_{kl} - \overline{x}_{kl})^{T}$$
 (8)

其中, $(x_i)_k$ 为一个分块类别中第i类训练样本中第j个样本子图像向量, \overline{x}_k 为第kl个分块类别所包含的所有训练样本子图像向量均值。容易证明 S_i 为非负定矩阵。定义准则函数:

$$J_{\varphi}(X) = X^{\mathsf{T}} S_t X \tag{9}$$

然后我们在满足上述准则函数最大条件下需要寻找一组满足标准正交的最优投影向量组 a_1,a_2,\cdots,a_r 和其所对应的特征值 v_1,v_2,\cdots,v_r 。在得到了每个小块所对应的特征值和特征向量后,用降序排序的方法重新排列 $p\times q$ 个小块的所有特征值 $v_1,v_2,\cdots,v_{r\times p\times q}$ 并找出这些特征值所对应的小块位置信息。取最大的 k 个特征值和其所对应的特征向量 d_1 , $d_2,\cdots,d_k(d_k\in R^{m_1\times n_1})$ 以及其所对应的位置信息 W_{ij} ,其中 ij 表示该特征向量属于哪个分块子图像 $(i=1,2,\cdots,p,j=1,2,\cdots,q)$ 。

4.2 特征抽取

通过以上方法得到了 k 个最大特征值所对应向量 v_1 、 v_2 , \cdots 、 $v_{r\times p\times q}$ 用于特征抽取。通过位置信息将一个 $m\times n$ 的原始 训练样本 M 分成 $p\times q$ 个子图像训练样 M_{11} , M_{12} , \cdots , $M_{p\times q}$ 。

训练样本为
$$M = egin{bmatrix} M_{11} & M_{12} & \cdots & M_{1q} \\ M_{21} & M_{22} & \cdots & M_{2q} \\ \cdots & \cdots & \cdots & \cdots \\ M_{p1} & M_{p2} & \cdots & M_{pq} \end{bmatrix}$$
,特征矩阵为

$$N=egin{array}{c} M_{11}\,v_{11}^{\mathsf{T}} \ M_{11}\,v_{12}^{\mathsf{T}} \ \dots \ M_{11}\,v_{1s1}^{\mathsf{T}} \ M_{12}\,v_{21}^{\mathsf{T}} \ M_{12}\,v_{22}^{\mathsf{T}} \ \dots \ M_{12}\,v_{2s2}^{\mathsf{T}} \ \dots \ M_{pq}\,v_{p\times q1}^{\mathsf{T}} \ M_{pq}\,v_{p\times q2}^{\mathsf{T}} \ \dots \ M_{pq}\,v_{p\times qs}^{\mathsf{T}} \ \dots \ M_{pq}\,v_{p\times qs}^{\mathsf{T}} \ \end{pmatrix}$$
,其中 v_{ij} 为特征向量, i 表示这个特征向 $M_{pq}\,v_{p\times qs}^{\mathsf{T}} \ M_{pq}\,v_{p\times qs}^{\mathsf{T}} \ M_{pq}\,v_{p$

量属于哪个小块,j 表示该特征向量是该小块中的第几个, $i=1,2,\cdots,p\times q$, $j=1,2,\cdots,s_{p\times q}$ 。这里 $M_{p\times q}$ 是要展开成一行的,乘以对应的 $s_{p\times q}$ 个特征向量后所得到的其实是有限个点所组成的向量,点的数目就是这里的 $s_{p\times q}$ 。对于每一个小块,

 $s_{p \times q}$ 是不尽相同的,这是与分块 PCA 的本质区别。对于分块 PCA,每个小块所取的特征向量个数是一定的,而对于本文方 法却是经过排序后的,所以每个小块所拥有的特征向量个数 不尽相同。最后将所得到的特征矩阵 N 作为新的训练样本 进行 PCA+LDA,以得到最后结果。

4.3 本文算法介绍

本文算法步骤简述如下:

- (1)选出每个人样本图像的前 5 幅、后 5 幅图像矩阵 M 分别作为原始样本($i=1,2,\dots,40,j=1,2,\dots,5$)。
- (2)将每幅图像分成 1个小块, $M_{i,l}$ ($i=1,2,\dots,40,j=1$, $2,\dots,5,l=1,2,\dots,p\times q$)。
- (3)对每个小块 $M_{i,1}$, $M_{i,2}$, …, $M_{i,l}$ 进行 PCA, 得到各个小块所对应特征值 $\lambda_{1,s}$, $\lambda_{2,s}$, …, $\lambda_{l,s}$ 和其所对应的特征向量 $v_{1,s}$, $v_{2,s}$, …, $v_{l,s}$ (s 为其所对应的小块信息)。
- $(4)M_{i,t}$ 为分块样本, v_{ij} 为所得特征向量, $N=M_{i,t}v_{ij}$ 得到新样本。
- (5)用新样本 $N=M_{i,l}v_{ij}$ 做 PCA+LDA 求出最优投影矩阵。
 - (6)用所求出的最优投影矩阵进行特征抽取和分类。 识别算法流程如图 1 所示。



5 实验结果与分析

5.1 MPCA 实验结果与分析

采用 ORL 人脸库进行实验。ORL 采用了 92×112 的分辨率。ORL 标准人脸库由 40 人、每人 10 幅图像组成,每个人的脸部表情和脸部细节有着不同程度的变化。实验样本选择模式为:前 5 幅训练、后 5 幅测试。实验采用 2×2 的分块模式,子矩阵的大小为 46×56 ,取投影轴数为 k,则特征矩阵的维数为 $2k \times 112$ 。

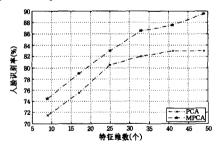


图 2 ORL人脸库上 MPCA 实验结果

通过图 2 可以看出,由于 MPCA 方法抽取图像局部特征,弱化了整体在分类识别中的影响,识别率比传统的 PCA 方法有了明显的提高。

5.2 MSPCA+LDA 实验结果与分析

本文采用 ORL 人脸库进行实验。ORL 采用了 92×112 的分辨率。ORL 标准人脸库由 40 人、每人 10 幅图像组成,每个人的脸部表情和脸部细节有着不同程度的变化。实验样本选择模式为:前 5 幅训练、后 5 幅测试。这里 MSPCA+LDA 方法采用 4×2 的分块方式,即 p=4,q=2,分类器采用最小距离分类器,实验结果如图 3 所示。

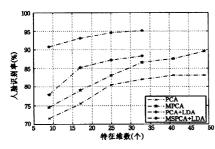


图 3 ORL 人脸库上 4 种识别算法比较

本文算法实际上是 PCA+LDA 与局部排序 PCA 的融合,其本质是在对数据图像进行 PCA+LDA 方法之前用局部排序 PCA 方法将数据图像压缩,使得其主能量最大化,然后将得到的新的训练样本进行 PCA+LDA。通过图 3 可以看到,MSPCA+LDA 方法在识别率上比 PCA 和 PCA+LDA都有明显提高。从表 1 的数据中可以看出,PCA 方法的最大识别率为 83%,MPCA 方法为 89.5%,PCA+LDA 方法为 88.25%,MSPCA+LDA 方法为 95.12%。

表1 ORL人脸库实验结果(%)

	PCA	MPCA	PCA+LDA	MSPCA+LDA
9	72%	74.5%	77.88%	90.75%
17	76%	79%	85. 25%	93%
25	81%	83%	87.13%	94.5%
33	82%	86.5%	88. 25%	95. 12%
41	83%	87.5%	_	_
49	83%	89.5%	_	_

结束语 本文提出了一种新型的分块排序 PCA 方法,然 后将经过分块排序 PCA 算法后得出的特征矩阵进行 LDA, 得到最后结果。与传统的线性鉴别方法 PCA、PCA+LDA 方 法相比,本文算法减弱了经典算法对于全局特征的依赖,增强 了局部特征在识别中的作用,而局部特征能够更好地反映图 像之间的差异,由于光照和人脸表情变化时,经典人脸识别算 法抽取的整体特征受这些条件的影响较大,因此识别效果会 受较大影响。而实际上当人脸表情和光照条件变化时,只有 部分的人脸区域变化明显而其他区域并无变化,所以分块后 抽取的人脸局部特征减弱了整体变化所带来的影响而加强了 局部变化的影响。这样就减弱了在识别过程中光照和人脸表 情变化给识别所带来的不利影响,从而提高了识别率。分块 降低了用于特征抽取的分块图像的图像向量的维数,同时增 加了分块图像训练样本的数目,小样本问题也随之消失,大大 降低了识别的复杂度。同时随着特征维数的降低,识别时间 也将减少。本文只给出了 4×2 分块方式的实验结果,并没有 给出多种分块方式。如何找出最佳分块方式以及是否存在使 得识别率最高的最优分块方式将成为以后研究的重点。

参考文献

[1] Belhumeur P N, Hespanha J P, Kriengman D J. Eigenfaces vs

- Fisherfaces: Recognition using class specific linearprojection [J]. IEEE Trans on Pattern Anal Machine Intell, 1997, 19(7): 711-720
- [2] 边肇棋,张学工. 模式识别(第二版)[M]. 北京:清华大学出版 社,1999:176-177 Bian Zhao-qi, Zhang Xue-gong. Pattern Recognition [M]. Beijing:Tsinghua University Press,2000
- [3] Kirby M, Sirovich L. Application of the KL procedure for the characterization of human faces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(1):103-108
- [4] Turk M, Pentland A. Face processing: Models for recognition [C] // Proceedings of Intelligent Robots and Computer Vision VIII. 1989,1:22-32
- [5] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86
- [6] Turk M, Pentland A. Face recognition using Eigenfaces [C]//
 Proceedings of the IEEE Conference on Computer Vision and
 Pattern Recognition, Hawaii, USA, 1991; 586-591
- [7] 金忠. 人脸图像特征抽取与维数研究 [D]. 南京:南京理工大学, 1999
 - Jin Zhong. Feature extraction and dimension research of human faces[D]. Nanjing; Nanjing University of science and technology, 1999
- [8] Yang Jian, Yu Yang-jing. Why can LDA be performed in PCA transformed space[J]. Pattern Recognition, 2003, 36:563-566
- [9] 杨键,杨静宇,叶辉,等. Fisher 线性鉴别分析的理论研究及其应用[J]. 自动化学报,2003,29(4):482-493
 Yang jian, Yang jing-yu, Ye Hui, et al. Theory of fisher linear discriminant analysis and its apllication[J]. Acta Automatica Sinica,2003,29(4):482-493
- [10] Jin Zhong, Yang Jing, et al. Face Recognition based on uncorrelated discriminant transformation [J]. Pattern Recognition, 2001, 34(7):1405-1416
- [11] Chen Li-fen, Liao Hong-yuan, et al. A new LDA-Based Face Recognition System Which Can Solve the Small Sample Size Problem [J]. Pattern Recognition, 2000, 33:1713-1726
- [12] Wu Xiao-jun, Josef K, Yu Yang-jing. A New Direct LDA Algorithm for Feature Extraction in Face Recognition [C]//Proceedings of the 17th International Conference on Pattern Recognition, Cambridge, UK, 2004; 545-548
- [13] 陈伏兵,高秀梅,张生亮,等. 基于分块 PCA 的人脸识别方法 [J]. 小型微型计算机系统,2006,27(10):1943-1947 Chen Fu-bing,Gao Xiu-mei,Zhang Sheng-liang, et al. Face Recognition based on modular PCA approach[J]. Mini-Micro Systems,2006,27(10):1943-1947
- [14] 陈伏兵,杨静宇. 分块 PCA 及其在人脸识别中的应用[J]. 计算机工程与设计,2007,28(8):1889-1892 Chen Fu-bing, Yang Jing-yu, Modular PCA and its application in face recognition[J]. Computer Engineering and Design,2007,28(8):1889-1892
- [10] Group W, Luck E, Skjellum A. Using MPI: Portable Parallel

(上接第 31 页)

- Programming with the Message Passing Interface [M]. Cambridge, MA: MIT Press, 1999
- [11] Brown R. Performance and Productivity Comparison Between OpenMP and MPI[J]. Int Parallel Prog, 2007, 35:441-458
- [12] 剡公孝,申卫昌,刘骊,等. 一种基于 MPICH 的高效矩阵相乘并 行算法[J]. 计算机工程与应用,2009,45(26);72-73
- Yan Gong-xiao, Shen wei-chang, Liu Li, et al. Effective matrix multiplication parallel algorithm based on MPICH[J]. Computer Engineering and Applications, 2009, 45(26); 72-73
- [13] 王之元,胡庆丰,陈娟. 能耗并行加速比:高性能计算系统综合性能的有效度量[J]. 计算机工程与科学,2009,31(11):113-116 Wang Zhi-yuan, Hu Qing-feng, Chen Juan. Power Parallel Speedup: An Effective Metric for Evaluating the Comprehensive Performance of High-Performance Computing Systems [J]. Computer Engineering and Science,2009,31(11):113-116