

# 分块 PCA 鉴别特征抽取能力的分析研究<sup>\*</sup>)

陈伏兵<sup>1,2</sup> 谢永华<sup>2</sup> 严云洋<sup>2</sup> 杨静宇<sup>2</sup>

(淮阴师范学院数学系 淮安 223001)<sup>1</sup> (南京理工大学计算机科学系 南京 210094)<sup>2</sup>

**摘要** 基于主成分分析(Principal Component Analysis, PCA),本文提出了分块 PCA 人脸识别方法。分块 PCA 从模式的原始数字图像出发,先对图像进行分块,对分块得到的子图像矩阵采用 PCA 方法进行特征抽取,从而实现模式的分类。新方法的特点是能有效地抽取图像的局部特征,正是这些特征使此类模式区别于彼类。在 Yale 人脸数据库上测试了该方法的鉴别能力。实验的结果表明,分块 PCA 在识别性能上优于通常的 PCA 方法,也优于基于 Fisher 鉴别准则的鉴别分析方法;Fisherfaces 方法、F-S 方法、组合鉴别方法,识别率可以达到 100%。

**关键词** 线性鉴别分析,主成分分析,特征抽取,分块主成分分析,人脸识别

## The Study of Extracting Ability of Discriminant Features for Modular PCA

CHEN Fu-Bing<sup>1,2</sup> XIE Yong-Hua<sup>2</sup> YAN Yun-Yang<sup>2</sup> YANG Jing-Yu<sup>2</sup>

(Department of Mathematics, Huaiyin Teachers College, Huai'an Jiangsu 223001)<sup>1</sup>

(Department of Computer Science, Nanjing University of Science and Technology, Nanjing 210094)<sup>2</sup>

**Abstract** Based on Principal Component Analysis(PCA), a new technique called Modular PCA is developed for human face recognition in this paper. First, in proposed approach, the original images are divided into smaller modular images, which are also called sub-images. Then, the well-known PCA method can be directly used to the sub-images obtained from the previous step for feature extraction, so the pattern classification can be implemented. The advantage of the represented way, when compared with conventional PCA algorithm on original images, is that the local discriminant features of the original patterns can be efficiently extracted, which are available to differentiate one class from another. To test Modular PCA and to evaluate its performance, a series of experiments were performed on Yale human face image databases. The experimental results indicate that the performance of the new method in terms of recognition rate is obviously superior to that of ordinary PCA algorithm on original images, and is superior to that of some discriminant analysis based on the Fisher discriminant criterion such as Fisherfaces, F-S and combination method.

**Keywords** Linear discriminant analysis(LDA), Principal component analysis(PCA), Feature extraction, Modular principal component analysis(Modular PCA), Face recognition

## 1 引言

模式识别中特征抽取研究肩负两方面的使命:一是寻找针对模式的最具鉴别性的描述,以使此类模式的特征能最大程度地区别于彼类;二是在适当的情况下实现模式数据描述的维数压缩,当描述模式的原始数据空间对应较大维数时,这一点非常有意义,甚至必不可少<sup>[1]</sup>。

众所周知,基于 Fisher 准则的线性鉴别被公认为特征抽取的最好方法之一。基于 Fisher 准则的鉴别分析有三种最为基本的方法:1) Wilks<sup>[2,3]</sup>等创立的经典 Fisher 鉴别法,近年来 Swets<sup>[4]</sup>、Belhumeur<sup>[5]</sup>和 Liu<sup>[6]</sup>等用来解决人脸识别问题;2)由 Foley 和 Sammon<sup>[7]</sup>建立起来的 F-S 线性鉴别法,后来 Duchene<sup>[8]</sup>等进一步拓展了这一方法, Tian<sup>[9]</sup>等将其用在图像识别领域;3)最近由 Yang<sup>[10,11]</sup>等提出的组合鉴别分析方法。与基于 Fisher 准则鉴别分析相提并论的主成分分析(Principal Component Analysis, PCA)<sup>[3,5,12]</sup>,又称 K-L 变换,被认为是线性鉴别分析中对特征空间进行降维的最有效的方法之一。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。Sirovich 和 Kirby<sup>[13,14]</sup>最初使用 PCA 有效地表示人脸;1991 年 Turk 和 Pentland<sup>[15]</sup>提出了著名的“Eigenfaces”方法;基于 PCA,结合 Fisher 鉴别准则,1997 年 Belhumeur<sup>[5]</sup>又给出了“Fisherfaces”方法。

以上方法在处理人脸等图像识别问题时,遵循一个共同的过程,即首先将图像矩阵转化为图像向量,然后以该图像向量作为原始特征进行线性鉴别分析。由于图像矢量的维数一般较高,比如分辨率为 100×80 的图像对应的图像向量的维数高达 8000,在如此高维的图像向量上进行线性鉴别分析不仅会遇到小样本问题,而且经常需要耗费大量的时间,有时还受研究件的限制(比如机器内存小),导致不可行。针对这个问题,人们相继提出不少解决问题的方法<sup>[10,11,16~21]</sup>。概括起来,这些方法可分为以下两类:一是从模式样本出发,在模式识别之前,通过降低模式样本特征向量的维数达到消除奇异性的目的。如金忠<sup>[16]</sup>通过降低图像的分辨率实现降维。二是从算法本身入手,通过发展直接针对小样本问题的算法来解决问题。Hong<sup>[17]</sup>, Liu<sup>[18]</sup>, Chen<sup>[19]</sup>, Yu<sup>[20]</sup>, Yang<sup>[10,11]</sup>等人分别在这方面进行过深入的探索,他们所建立的算法理

<sup>\*</sup> 基金项目:国家自然科学基金(60472060)和江苏省自然科学基金(05KJD520050)资助。陈伏兵 副教授,博士研究生,主要研究方向:时间序列、模式识别、图像处理等;谢永华 博士研究生,主要研究方向:图像处理、模式识别等;严云洋 副教授,博士研究生,研究方向为模式识别、图像处理等;杨静宇 教授,博士生导师,主要研究领域:计算机视觉、信息融合、模式识别、智能机器人等。

论为这一问题的解决奠定了基础。

本文秉承 PCA 的思想,利用其“代表数据样本非常有效的特点”<sup>[3]</sup>,从原始数字图像出发,在模式识别之前,先对图像进行分块,对分块得到的子图像矩阵采用 PCA 进行鉴别分析—这种特征抽取方法称为分块主成分分析(Modular PCA)或单元主成分分析。这样做主要基于下面的考虑:在人脸识别中当人脸表情和光照条件变化较大时,由于通常的 PCA 方法抽取的是图像的全局特征,因此识别效果并不理想<sup>[22]</sup>。而实际上,当人脸表情和光照条件变化时,仅部分人脸区域变化明显,其它部分变化不大,甚至无变化,对划分后的子图像进行鉴别分析可以捕捉人脸的局部信息特征,从而有利于识别;在 Yale 人脸库上的试验结果表明,本文提出的方法在识别性能上明显优于 PCA、Fisherfaces、F-S 和组合鉴别分析方法,识别率可以达到 100%。

## 2 基本概念和常用的线性鉴别分析方法

### 2.1 基本概念

#### 2.1.1 向量化矩阵

设  $A=(A_1, A_2, \dots, A_n) \in R^{m \times n}$ , 定义  $mn \times 1$  的向量

$$\text{Vec}(A) = \begin{bmatrix} A_1 \\ A_2 \\ \vdots \\ A_n \end{bmatrix} \quad (1)$$

这是把矩阵  $A$  按列向量依次排成的向量,往往称这个程序叫矩阵  $A$  的向量化<sup>[23]</sup>。

#### 2.1.2 散布矩阵

设模式类别有  $C$  个:  $\omega_1, \omega_2, \dots, \omega_c$ , 第  $i$  类有训练样本图像矩阵  $n_i$  个:  $A_{i1}, A_{i2}, \dots, A_{in_i}$ , 每个样本图像是  $m \times n$  矩阵,将其向量化得到相应的图像向量,  $A_{ij}$  对应的图像向量表示为  $\xi_{ij}$ , 即  $\xi_{ij} = \text{Vec}(A_{ij})$ ,  $N = \sum_{i=1}^C n_i$ , 为训练样本总数, 则类间散布矩阵  $S_b$ 、类内散布矩阵  $S_w$  和总体散布矩阵  $S_t$  分别定义为:

$$S_b = \frac{1}{N} \sum_{i=1}^C n_i (\xi_i - \bar{\xi})(\xi_i - \bar{\xi})^T \quad (2)$$

$$S_w = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{n_i} (\xi_{ij} - \xi_i)(\xi_{ij} - \xi_i)^T \quad (3)$$

$$S_t = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{n_i} (\xi_{ij} - \bar{\xi})(\xi_{ij} - \bar{\xi})^T \quad (4)$$

其中  $\xi_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \xi_{ij}$  为第  $i$  类训练样本的均值,  $\bar{\xi} = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{n_i} \xi_{ij}$  为全体训练样本的均值。

由(2)、(3)和(4)的定义知,  $S_w, S_b, S_t$  均为非负定矩阵,而且满足  $S_t = S_b + S_w$ 。

## 2.2 常用的线性鉴别分析方法

### 2.2.1 PCA 方法

主成分分析(Principal Component Analysis, PCA)又称 K-L 变换,是寻求有效的线性变换的经典方法之一,其目的是在最小均方意义下寻找最能代表原始数据的投影方向,从而达到对特征空间进行降维的目的<sup>[3]</sup>。

定义准则函数

$$J(X) = X^T S_t X \quad (5)$$

选取一组标准正交且使得准则函数(2)达到极值的向量  $X_1, \dots, X_d$  作为投影轴。其物理意义是使投影后所得特征的总体散布量(类间散布量与类内散布量之和)最大。事实上,这一组最优投影轴应取为  $S_t$  的  $d$  个最大本征值所对应的标

准正交的本征向量<sup>[3]</sup>。

令  $P=(X_1, \dots, X_d)$ , 则投影变换为  $Y=P^T X$ 。

### 2.2.2 FDA 方法

经典的 Fisher 线性鉴别分析(Fisher Discriminant Analysis, FDA)<sup>[3]</sup>旨在通过最优化准则函数(6)或(7)找到一个最优的投影矩阵  $W_{opt}$ 。

$$J_c(W) = \frac{|W^T S_b W|}{|W^T S_w W|} \quad (6)$$

$$J_r(W) = \text{tr}[(W^T (S_w W)^{-1} (W^T S_b W))] \quad (7)$$

事实上,经典的 Fisher 线性鉴别分析的最优投影轴,即  $W_{opt}$  的列向量  $u_1, u_2, \dots, u_d$  一般取为广义特征方程  $S_b X = \lambda S_w X$  的  $d$  个最大的本征值所对应的本征向量<sup>[3]</sup>, 即  $u_1, u_2, \dots, u_d$  满足以下条件:

$$S_b u_j = \lambda_j S_w u_j, j=1, \dots, d, \text{ 其中 } \lambda_1 \geq \dots \geq \lambda_d$$

### 2.2.3 F-S 方法

Foley-Sammon 线性鉴别分析旨在寻找一组最优鉴别矢量集  $\varphi_1, \dots, \varphi_d$ , 它们在最大化 Fisher 准则函数(6)或(7)的同时满足以下正交条件:

$$\varphi_i^T \varphi_j = 0, \forall i \neq j, i, j=1, \dots, d$$

事实上, Foley-Sammon 最佳鉴别矢量集的第一个矢量取为 Fisher 最佳鉴别方向, 即广义本征方程  $S_b X = \lambda S_w X$  的最大本征值所对应的单位本征向量  $\varphi_1$ 。在 F-S 最佳鉴别矢量集的前  $i$  个鉴别矢量  $\varphi_1, \dots, \varphi_i$  求出之后, 第  $i+1$  个鉴别矢量  $\varphi_{i+1}$  为广义本征方程  $B_i S_b \varphi = \lambda S_w \varphi$  的最大本征值所对应的本征向量, 其中  $B_i = I_n - D_i^T (D_i (S_w^{-1} D_i^T)^{-1} D_i S_w^{-1})$ ,  $D_i = (\varphi_1, \varphi_2, \dots, \varphi_i)^T$ <sup>[16]</sup>。

令  $P=(\varphi_1, \dots, \varphi_d)$ , 则投影变换为  $Y=P^T X$ 。

### 2.2.4 Fisherfaces 方法

经典的 Fisherfaces 构架最早是由 Belhumeur<sup>[5]</sup>等人建立的。在该构架中, 首先采用 PCA 将高维的图像向量空间压缩为  $N-C$  维的特征空间, 然后采用经典的线性鉴别分析将维数压缩为  $d(d \leq C-1)$ , 即 Fisherfaces 方法等价于 PCA + FDA。

### 2.2.5 组合方法

组合(Combination)方法的基本思想是: 当  $S_t$  奇异时, 设  $m = \text{rank}(S_t)$ ,  $\beta_1, \dots, \beta_m$  为  $S_t$  的非零本征值所对应的标准正交的本征向量, 令  $P=(\beta_1, \dots, \beta_m)$ , Fisher 最优鉴别特征的抽取过程可分为两步进行<sup>[10,11]</sup>: 第一步, 作 K-L 变换,  $Y=P^T X$  将高维的原始样本压缩为  $m$  维; 第二步, 在变换空间  $R^m$  内, 利用 Fisher 鉴别分析方法进行特征抽取。

设变换空间  $R^m$  内的类间散布矩阵、类内散布矩阵和总体散布矩阵分别表示为  $\tilde{S}_b, \tilde{S}_w, \tilde{S}_t$ , 则  $\tilde{S}_b = P^T S_b P$ ,  $\tilde{S}_w = P^T S_w P$ ,  $\tilde{S}_t = P^T S_t P$ , 且  $\tilde{S}_b, \tilde{S}_w$  为非负定阵,  $\tilde{S}_t$  为正定阵(必可逆)。于是, 该情况下的有效鉴别矢量分为两类: 第一类满足条件  $Y^T \tilde{S}_w Y = 0$  和  $Y^T \tilde{S}_b Y > 0$ ; 第二类满足条件  $Y^T \tilde{S}_w Y > 0$  和  $Y^T \tilde{S}_b Y > 0$ 。即第一、二类最优鉴别矢量可分别在  $\tilde{S}_w$  的零空间  $\tilde{\Phi}_w^\perp$  和非零空间  $\tilde{\Phi}_w$  里求得。设  $\tilde{S}_w$  的标准正交的特别向量是  $\gamma_1, \dots, \gamma_q, \gamma_{q+1}, \dots, \gamma_m$ , 其中前  $q$  为非零特征值对应的特征向量, 记  $\tilde{\Phi}_w = \text{span}\{\gamma_1, \dots, \gamma_q\}$ ,  $\tilde{\Phi}_w^\perp = \text{span}\{\gamma_{q+1}, \dots, \gamma_m\}$ , 则  $R^m = \tilde{\Phi}_w \oplus \tilde{\Phi}_w^\perp$ 。令  $P_1 = (\gamma_{q+1}, \dots, \gamma_m)$ ,  $\tilde{S}_b = P_1^T \tilde{S}_b P_1$ , 求出  $\tilde{S}_b$  的正交特征向量  $Z_1, \dots, Z_l$ , 一般地  $l=C-1$ , 那么  $\tilde{\Phi}_w^\perp$  中的最优鉴别矢量是  $Y_j = P_1 Z_j, j=1, \dots, l$ ; 令  $P_2 = (\gamma_1, \dots, \gamma_q)$ ,  $\tilde{S}_t = P_2^T \tilde{S}_t P_2$ ,  $\tilde{S}_t = P_2^T \tilde{S}_t P_2$ , 求广义本征方程  $\tilde{S}_b \varphi = \lambda \tilde{S}_t \varphi$  的  $d-l$  个最大本征值所对应的本征向量, 那么  $\tilde{\Phi}_w$  中的最优鉴别矢

量是  $Y_j = P_2 Z_j, j = l+1, \dots, d$ 。

令  $Q = (Y_1, \dots, Y_l, Y_{l+1}, \dots, Y_d)$ , 则线性变换为  $Z = (PQ)^T X$ 。

通过 2.2.1 至 2.2.5 节的特征抽取过程, 每个图像向量  $\xi$  对应一个特征向量  $B = U^T \xi$  ( $U$  为线性变换矩阵)。对此特征向量, 可以利用最小距离分类器进行分类。第  $i$  类训练图像样本的均值向量  $\bar{\xi}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \xi_{ij}$  的特征向量为  $\bar{B}_i = U^T \bar{\xi}_i, i = 1, 2, \dots, C$ 。对测试样本  $\xi$ , 计算  $d(\bar{B}_i, B) = \|\bar{B}_i - B\|_{m_1}, i = 1, 2, \dots, C$ 。如果  $d(\bar{B}_i, B) = \min_i d(\bar{B}_i, B)$ , 那么  $\xi \in \omega_i$ 。

### 3 分块主成分分析 (Modular PCA)

#### 3.1 Modular PCA 思想与最优投影矩阵

分块 PCA 先将一个  $m \times n$  的图像矩阵  $I$  分成  $p \times q$  分块图像矩阵 (类似于线性代数中矩阵的分块), 即

$$I = \begin{pmatrix} I_{11} & I_{12} & \dots & I_{1q} \\ I_{21} & I_{22} & \dots & I_{2q} \\ \dots & \dots & \dots & \dots \\ I_{p1} & I_{p2} & \dots & I_{pq} \end{pmatrix}$$

其中每个子图像矩阵  $I_{kl}$  是  $m_1 \times n_1$  矩阵,  $pm_1 = m, qn_1 = n$ , 然后将所有训练图像样本的子图像矩阵看作训练样本图像向量施行 PCA 方法。

训练样本图像  $A_{ij}$  的  $p \times q$  分块矩阵表示为

$$A_{ij} = \begin{pmatrix} (A_{ij})_{11} & (A_{ij})_{12} & \dots & (A_{ij})_{1q} \\ (A_{ij})_{21} & (A_{ij})_{22} & \dots & (A_{ij})_{2q} \\ \dots & \dots & \dots & \dots \\ (A_{ij})_{p1} & (A_{ij})_{p2} & \dots & (A_{ij})_{pq} \end{pmatrix} \quad (8)$$

令  $(\eta_{ij})_{kl} = \text{Vec}(A_{ij})_{kl}, k = 1, 2, \dots, p, l = 1, 2, \dots, q$ , 则  $(\eta_{ij})_{kl} \in R^{m_1 n_1}$ , 于是所有训练图像样本的子图像矩阵的总体散布矩阵为:

$$S = \frac{1}{M} \sum_{i=1}^C \sum_{j=1}^{n_i} \sum_{k=1}^p \sum_{l=1}^q ((\eta_{ij})_{kl} - \eta) ((\eta_{ij})_{kl} - \eta)^T \quad (9)$$

其中  $M = (\sum_{i=1}^C n_i) pq = Npq$  表示训练样本子图像矩阵总数,  $\eta = \frac{1}{M} \sum_{i=1}^C \sum_{j=1}^{n_i} \sum_{k=1}^p \sum_{l=1}^q (\eta_{ij})_{kl}$  为所有训练样本子矩阵均值矩阵。容易证明  $S$  为  $m_1 n_1 \times m_1 n_1$  非负定矩阵。

与 PCA 类似, 需要寻找一组满足标准正交的最优投影向量组  $Z_1, Z_2, \dots, Z_r$ 。

**定理 1** 最优投影向量组  $Z_1, Z_2, \dots, Z_r$  可取为  $S$  的  $r$  个最大本征值所对应的标准正交的本征向量。

令  $Q = [Z_1, Z_2, \dots, Z_r], Q \in R^{(m_1 n_1) \times r}$ , 称为最优投影矩阵。

#### 3.2 特征抽取

最优投影矩阵  $Q = [Z_1, Z_2, \dots, Z_r]$  用于特征抽取。训练样本  $A_{ij}$  (见(8)) 的特征矩阵为:

$$B_{ij} = \begin{pmatrix} Q^T (\eta_{ij})_{11} & Q^T (\eta_{ij})_{12} & \dots & Q^T (\eta_{ij})_{1q} \\ Q^T (\eta_{ij})_{21} & Q^T (\eta_{ij})_{22} & \dots & Q^T (\eta_{ij})_{2q} \\ \dots & \dots & \dots & \dots \\ Q^T (\eta_{ij})_{p1} & Q^T (\eta_{ij})_{p2} & \dots & Q^T (\eta_{ij})_{pq} \end{pmatrix} \quad (10)$$

其大小为  $pr \times q$ 。

#### 3.3 分类

通过分块 PCA 后, 每个图像对应一个特征矩阵, 对此特征矩阵, 利用最小距离分类器进行分类。第  $i$  类训练样本的

均值图像矩阵  $\bar{A}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} A_{ij} (i = 1, 2, \dots, C)$  的分块图像矩阵为:

$$\bar{A}_i = \begin{pmatrix} (\bar{A}_i)_{11} & (\bar{A}_i)_{12} & \dots & (\bar{A}_i)_{1q} \\ (\bar{A}_i)_{21} & (\bar{A}_i)_{22} & \dots & (\bar{A}_i)_{2q} \\ \dots & \dots & \dots & \dots \\ (\bar{A}_i)_{p1} & (\bar{A}_i)_{p2} & \dots & (\bar{A}_i)_{pq} \end{pmatrix}$$

其特征矩阵 ( $pr \times q$ ) 为

$$\bar{B}_i = \begin{pmatrix} Q^T (\bar{\eta}_i)_{11} & Q^T (\bar{\eta}_i)_{12} & \dots & Q^T (\bar{\eta}_i)_{1q} \\ Q^T (\bar{\eta}_i)_{21} & Q^T (\bar{\eta}_i)_{22} & \dots & Q^T (\bar{\eta}_i)_{2q} \\ \dots & \dots & \dots & \dots \\ Q^T (\bar{\eta}_i)_{p1} & Q^T (\bar{\eta}_i)_{p2} & \dots & Q^T (\bar{\eta}_i)_{pq} \end{pmatrix} \quad (11)$$

其中  $(\bar{\eta}_i)_{kl} = \text{Vec}((\bar{A}_i)_{kl}), k = 1, 2, \dots, p, l = 1, 2, \dots, q$

容易证明

$$\bar{B}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} B_{ij}, i = 1, 2, \dots, C \quad (12)$$

测试样本

$$I = \begin{pmatrix} I_{11} & I_{12} & \dots & I_{1q} \\ I_{21} & I_{22} & \dots & I_{2q} \\ \dots & \dots & \dots & \dots \\ I_{p1} & I_{p2} & \dots & I_{pq} \end{pmatrix}$$

的特征矩阵 ( $pr \times q$ ) 为

$$B = \begin{pmatrix} Q^T \eta_{11} & Q^T \eta_{12} & \dots & Q^T \eta_{1q} \\ Q^T \eta_{21} & Q^T \eta_{22} & \dots & Q^T \eta_{2q} \\ \dots & \dots & \dots & \dots \\ Q^T \eta_{p1} & Q^T \eta_{p2} & \dots & Q^T \eta_{pq} \end{pmatrix} \quad (13)$$

其中  $\eta_{kl} = \text{Vec}(I_{kl}), k = 1, 2, \dots, p, l = 1, 2, \dots, q$ 。计算

$$d(\bar{B}_i, B) = \|\bar{B}_i - B\|_{m_1}, i = 1, 2, \dots, C$$

其中  $\| * \|_{m_1}$  表示矩阵“\*”的  $m_1$  范数。如果  $d(\bar{B}_i, B) = \min_i d(\bar{B}_i, B)$ , 那么  $A \in \omega_i$ 。

在人脸图像识别中, 经常会遭遇小样本问题, 即样本图像向量的维数大于训练样本数的情况。用分块 PCA 方法进行鉴别分析时, 当子图像的大小 ( $m_1 \times n_1$ ) 与原始图像划分的块数  $pq$  满足  $m_1 n_1 \leq Npq (N = \sum_{i=1}^C n_i$  为训练样本总数) 时, 我们可以避免小样本问题, 即这时问题转化为大样本问题, 于是关于大样本问题的算法和理论都可以应用。

此外, 需要指出的是, 用分块 PCA 方法进行鉴别分析时, 若分块矩阵是  $1 \times 1$  的, 即分块矩阵中只有一个子矩阵, 此子矩阵就是原始图像本身, 那么分块 PCA 就是 PCA。这表明 PCA 是分块 PCA 的特殊情况, 因此从这个意义上说, 本文的分块 PCA 方法是 PCA 方法的推广。

### 4 实验结果与分析

我们在 Yale 人脸数据库上验证 Modular PCA 的鉴别能力。Yale 人脸图像库由 15 人, 每人 11 幅图像组成, 每人的不同图像有较大的表情变化和光照条件变化。每幅图像的分辨率是  $100 \times 80$ 。图 1 是 Yale 人脸库中某一人的 5 幅图像。



图 1 Yale 人脸库中一人的 5 幅图像

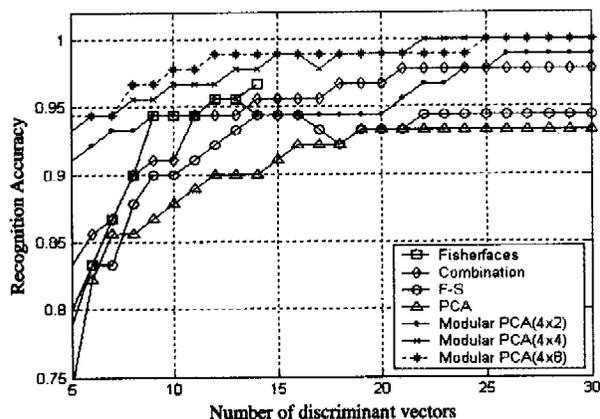


图2 Yale人脸库上实验结果

我们将每人的前5幅人脸图像样本作为训练样本,后6幅图像作为测试样本。这样,训练样本总数为75个,测试样本总数为90个。利用Modular PCA方法,若取 $k$ 个投影轴,得到的特征矩阵的大小是 $(pk) \times q$ 。然后,在投影空间内,采

表1 Fisherfaces、F-S、组合、PCA与MPCA方法在Yale人脸库上实验最优鉴别矢量维数、误识样本数目、正确识别率(%)、特征抽取时间、样本识别时间以及特征抽取和识别时间(时间单位:秒)比较

比较项目	Fisherfaces	F-S	Combination	PCA	Modular PCA		
					2×4	4×4	4×8
最优投影轴数	14	37	21	25	21	22	25
最优特征维数	14	37	21	25	42×4	88×4	100×8
误识样本数目	3	4	2	4	1	0	0
正确识别率	96.7	95.6	97.8	95.6	98.9	100	100
特征抽取时间	6.13	8.05	6.52	5.00	58.19	24.17	15.80
样本识别时间	0.02	0.03	0.02	0.06	0.27	0.41	0.58
总时间	6.14	8.08	6.54	5.06	58.45	24.58	16.38

注:表中的总时间等于特征抽取时间与样本识别时间之和。

表1的数据表明,在识别率方面,对给出的原始图像的三种划分 $2 \times 4$ 、 $4 \times 4$ 和 $4 \times 8$ ,Modular PCA的识别结果优于其它任意一种方法的结果。具体地说,Fisherfaces方法的结果是96.7%,Foley-Saman方法的结果是95.6%,组合鉴别分析方法是97.8%,PCA方法的结果是95.6%,而Modular PCA方法的结果不低于98.9%,最高时达到100%。在特征抽取方面,对原始图像的 $2 \times 4$ 、 $4 \times 4$ 划分来说,Modular PCA方法花费的时间明显多于其它几种方法花费的时间。这是因为在 $2 \times 4$ 划分情况下,处理的问题都是小样本问题,需要计算1000级总体散布矩阵的特征向量。计算如此高维的特征向量,编程时,我们采用直接计算的方法(可以采用间接的方法),这是很耗时的,但在现有的机器条件下它是可行的!而其它几种方法需要计算8000级矩阵的特征向量,现有的条件下直接计算是不可行的,但由于它们使用奇异值分解理论,只需计算75级散布矩阵的特征向量,从而节省了大量的时间;对 $4 \times 4$ 划分的情况,虽然处理的问题不是小样本问题,但它要直接计算500级总体散布矩阵的特征向量;在样本识别方面,Modular PCA方法使用的时间多于其它几种方法的时间,这是最佳鉴别特征维数决定的。一般地,Modular PCA方法抽取特征是按块进行的,它获得的特征的维数大于其它几种方法得到的特征的维数。如Fisherfaces方法得到的最佳鉴别特征维数是14,而Modular PCA方法对 $2 \times 4$ 、 $4 \times 4$ 和 $4 \times 8$ 三种分块获得的最佳鉴别特征维数分别是168

用最小距离分类器进行分类,其中的距离是矩阵的 $m_1$ 距离。试验的结果,正确识别率和投影轴之间的对应关系见图2。图2中给出了对Yale原始图像矩阵进行 $4 \times 2$ 、 $4 \times 4$ 和 $4 \times 8$ 三种分块后分别用本文方法实验得到的结果。三种情况下模块子矩阵的大小分别为 $25 \times 40$ 、 $25 \times 20$ 、 $25 \times 10$ ,对应的特征矩阵的大小分别是 $4k \times 2$ 、 $4k \times 4$ 、 $4k \times 8$ ( $k$ 为投影轴数)。同时,为便于比较也给出了Fisherfaces方法、F-S方法、组合方法和PCA方法的结果。从图中可以看出,对三种模块图像,本文方法的结果均明显优于其它几种方法的结果。

PCA方法、Fisherfaces方法、F-S方法、组合方法和分块PCA方法(本文方法)的本质都属于线性鉴别分析方法。为了进一步说明它们的性能,我们对它们在Yale人脸库上实验得到最高识别率时的最优鉴别矢量维数、误识样本数目、正确识别率(%)、特征抽取时间、样本识别时间以及特征抽取和样本识别总时间(时间单位:秒)进行了比较。我们的实验是使用Matlab语言编程在Inter(R)1.80 GHz、内存384MB计算机上进行的。实验的结果见表1。

( $42 \times 4$ )、352( $88 \times 4$ )和800( $100 \times 8$ )。

总体而言,分块PCA方法的鉴别效果好于通常的PCA方法和基于Fisher准则的鉴别分析方法;Fisherfaces、F-S和组合方法。其原因是:通过对原始数字图像分块,利用主成分分析,抽取到每一单元块的局部特征,这些局部特征与直接将其它方法用于原始图像抽取的全局特征相比对模式更具有鉴别性的描述,能反映图像的差异。以上的实验结果验证了我们的分析。

**结束语** 本文提出了分块主成分分析的人脸识别方法。所提出的方法是一种直接基于子图像向量的线性鉴别分析方法,与以往的基于图像向量的线性鉴别方法(比如Fisherfaces、F-S、组合方法或PCA方法)相比,它的突出优点是能够抽取到图像的局部特征,这些局部特征更好地反映了图像之间的差异,便于模式识别。此外,由于对原始数字图像进行分块,可以方便地在较小的图像上使用鉴别分析的方法,使其过程简便,如Modular PCA可以避免使用矩阵的奇异值分解理论。Modular PCA也可以用于人脸以外的其它图像识别。不过,在实验中我们发现,对同一个数据库,原始图像采用不同的分块,获得的最高识别率一般不同。如何寻找或是否存在最佳分块划分获得更最高识别率的问题值得进一步研究。

## 参考文献

- 1 徐勇.几种线性与非线性特征抽取方法及人脸识别应用:[博士论文].南京:南京理工大学,2004

2 Wilks S S. Mathematical Statistics. New York : Wiley Press, 1962

3 Duda R, Hart P. Pattern Classification and Scene Analysis. New York ; Wiley Press,1973

4 Swets D L, Weng J. Using discriminant eigenfeatures for image retrieval. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996,18(8); 831~836

5 Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs Fisherfaces ; Recognition using class specific linear projection. IEEE Trans on Pattern Anal Machine Intell, 1997, 19(7); 711~720

6 Liu Cheng-Jun, Wechsler H. A shape and texture-based enhanced Fisher classifier for face recognition. IEEE Transactions on Image Processing, 2001, 10(4); 598~608

7 Foley D H, Sammon J W Jr. An optimal set of discriminant vectors. IEEE Transactions on Computer, 1975, 24(3); 281~289

8 Duchene J, Leclercq S. An optimal Transformation for discriminant and principal component analysis. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1988,10(6); 978~983

9 Tian Q. Image classification by the Foley-Sammon transform. Optical Engineering, 1986, 25(7); 834~839

10 杨键,杨静宇,叶晖,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

11 Yang Jian, Yang Jing-Yu. Why can LDA be performed in PCA transformed space? [J]. Pattern Recognition, 2003, 36; 563~566

12 边肇祺, 张学工. 模式识别(第二版)[M]. 北京: 清华大学出版社, 1999

13 Sirovich L, Kirby M. Low-Dimensional Procedure for Character-

ization of Human Faces. J Optical Soc Am, 1987, 4; 519~524

14 Kirby M, Sirovich L. Application of the KL Procedure for the Characterization of Human Faces. IEEE Trans Pattern Analysis and Machine Intelligence, 1990, 12(1); 103~108

15 Turk M, Pentland A. Eigenfaces for Recognition. J Cognitive Neuroscience, 1991, 3(1); 71~86

16 金忠. 人脸图像特征抽取与维数研究:[博士论文]. 南京: 南京理工大学, 1999

17 Hong Z Q, Yang J Y, et al. Optimal discriminant plane for a small number of samples and design method of classifier on the plane [J]. Pattern Recognition, 1991, 24(4); 317~324

18 Liu K, Yang J-Y, et al. An efficient algorithm for Foley-Sammon optimal set of discriminant vectors by algebraic method [J]. International Journal of Pattern Recognition and Artificial Intelligence, 1992, 6(5); 817~829

19 Liu K, Cheng Y-Q, Yang J-Y, et al. Algebraic feature extraction for image recognition based on an optimal discriminant criterion [J]. Pattern Recognition, 1993, 26(6); 903~911

20 Chen Li-Fen, Mark Liao H-Y, Ko M-T, et al. A new LDA-based face recognition system which can solve the small sample size problem [J]. Pattern Recognition, 2000, 33(10); 1713~1726

21 Yu Hua, Yang Jie. A direct LDA algorithm for high-dimensional data—with application to face recognition [J]. Pattern Recognition, 2001, 34(10); 2067~2070

22 Gottumukkal R, Asari V K. An improved face recognition technique based on modular PCA approach [J]. Pattern Recognition Letters, 2004, 25; 429~436

23 王松桂. 线性模型的理论及其应用. 合肥: 安徽教育出版社, 1987

(上接第 139 页)

表 1 预取算法应用前后 TPC-C 测试数据比较

	数据量 (warehouse)	吞吐量 (tmpC)	New-Order 事务的响应时间(s)		
			90%	平均	最大
预取前	19	212.7	2.93	2.6	48.04
	20	224.07	5.34	3.63	90.23
预取后	19	215.5	2.7	2.16	75.89
	20	225.5	4.17	3.21	82.5

从实验结果可以看出,实现预取后数据库吞吐量有一定的提高,但不是很明显,响应时间有比较大的降低。根据事务处理性能委员会(TPC, Transaction Processing Performance Council)2001年制定的 TPC-C 测试标准<sup>[7]</sup>,符合:

- (1)  $9 \leq (\text{tmpC 值} / \text{warehouse 数}) \leq 12.86$
- (2) 90% New-Order 事务的响应时间  $\leq 5 \text{ sec.}$

要求的最大 warehouse 数即为 TPC-C 测试结果。从表 1 可以看出,预取前数据库 TPC-C 测试的结果为 19 warehouse, 预取后数据库 TPC-C 测试结果可达到 20 warehouse 或以上。以上结果表明,实现预取后 PostgreSQL 的性能有了提高。在实验的过程中,通过取不同的 BUF\_READ\_AHEAD\_LINEAR\_AREA 值,该算法对性能都有一定程度的提高,能有效地提高磁盘块的平均存取速度。

**结论** 为了提高数据库性能,减少存取磁盘块所需要的平均时间,本文给出了 PostgreSQL 上顺序预取的算法,实验结果表明了算法的有效性。在以后的工作中,我们将进一步研究其它预取技术<sup>[8~10]</sup>在数据库上的应用,并与顺序预取技术作比较。

参 考 文 献

1 Palmer M, Zdonik S, Fide; A Cache that Learns to Fetch. In;

Proc. of the 1991 Int Conf. on Very Large Databases, Barcelona, Catalonia, Spain, Sep. 1991. 255~264

2 Shah P, Paris J-F, Amer A, Long D D E. Identifying Stable File Access Patterns. In; Proc. of the 21st IEEE Symposium on Mass Storage Systems and Technologies (MSST 2004), College Park, MD, April 2004. 159~163

3 DB2 Administration Guide, Prefetching Data into the Buffer Pool. <https://aurora.vcu.edu/db2help/db2d0/fra me3.htm#prefetch>

4 Smith A J. Sequentiality and Prefetching in Database Systems. ACM Transactions on Database Systems (TODS), 1978, 3(3); 223~247

5 Kroeger T M, Long D D E. Design and Implementation of a Predictive File Prefetching Algorithm. In; Proc. of the 2001 USENIX Annual Technical Conf. Boston, Massachusetts, USA, June 2001. 105~118

6 Silberschatz A, Korth H F, Sudarshan S 著, 阳冬青, 唐世渭, 等译. 数据库系统概念(原书第 4 版). 北京: 机械工业出版社, 2003. 275~289

7 Transaction Processing Performance Council. <http://www.tpc.org>. TPC Benchmark™C - Standard Specification, Revision 5. 0. February 26, 2001. 60~70

8 Vitter J S, Krishnan P. Optimal Prefetching via Data Compression. Journal of the ACM, 1996, 43; 771~793

9 Curewitz K, Krishnan P, Vitter J S. Practical Prefetching via Data Compression. In; Proc. of the 1993 ACM SIGMOD Int. Conf. on Management of Data, Washington, D. C., USA, May 1993. 771~793

10 曹新平, 刘美华, 等. 预取技术研究进展. 计算机科学, 2003, 30(8)