

# 对单训练样本的人脸识别问题的研究<sup>\*</sup>)

张生亮 陈伏兵 杨静宇

(南京理工大学计算机科学系 南京 210094)

**摘要** 现在许多人脸识别算法都是在假定每个人提供了多幅训练样本的情况下展开的,对每人只有一幅训练图像的识别问题研究得很少,而实际中往往每人只提供了一幅图像。本文对这一问题进行了研究,给出了一些生成虚拟训练样本的方法;提出了基于类间散度最大的二维主分量分析方法,在 ORL 库上用单训练样本取得了 75.28% 的识别结果。

**关键词** 主分量分析(PCA),二维主分量分析(2DPCA),Fisherface,虚拟样本

## Some Researches for Face Recognition with One Training Image per Person

ZHANG Sheng-Liang CHEN Fu-Bing YANG Jing-Yu

(Department of Computer Science, Nanjing University of Science & Technology, Nanjing 210094)

**Abstract** Nowadays many algorithms for face recognition are under the postulate that each person has many training images. There are few study with the one training sample per person. While each person may only provide one registered photo in most cases. We solve this problem by add virtual images generating from the given training image, and study the differences of the recognition rates between PCA, Fisherface, (PC)<sup>2</sup>A and Two Dimension PCA(2DPCA). In this paper, a new 2DPCA which is based on the Maximum Margin Criterion is proposed. The average recognition rate on ORL face-databases achieves 75.28% only using one training image per person.

**Keywords** PCA, 2DPCA, Fisherface, Virtual samples

## 1 引言

人脸识别过程中抽取有效的特征是一个关键的问题,特征的好坏决定着识别率的高低。如何抽取有效的特征,一方面与算法本身有关,另一方面也与训练样本的质量和数量密切相关。抽取方法有 PCA<sup>[1]</sup>(主分量分析)、2DPCA<sup>[2,3]</sup>(二维 PCA)、Fisherface<sup>[4]</sup>、Fisher 鉴别分析(Fisher linear discriminant, LDA)、统计不相关的鉴别分析<sup>[5]</sup>(ULDA)等。这些方法都要求对每人有一定的训练样本数量,如在 ORL 上的许多实验都是在假定每人有 10 幅图像,其中 5 幅用于训练 5 幅用于识别得到的测试结果。通常每人至少两幅图像用于训练。对每人只有一个训练样本的人脸识别,已有的研究涉及得很少。由于在许多的场合,我们只有某人的一张注册照片,我们只能做单样本的人脸识别。因此对这一问题进行研究和探讨是有意义的,也是完全必要的。

在每人只有一个训练样本的情况下,将直接导致类内散度为零。这样,一些基于 Fisher 准则的方法就无法直接进行,而 PCA 和二维 PCA 尽管可以直接应用,但识别率也不高。在单训练样本情况下,通过变换增加若干虚拟样本,是解决这一问题的唯一方法。Shiguang Shan<sup>[6]</sup>等的处理方法是增加一些虚拟样本后,用 Fisherface 进行识别。但根据我们的计算,Fisherfaces 在这种情况下的识别率并不高。Jianxin Wu, Zhi-Hua Zhou<sup>[7]</sup>利用原始图像与积分投影的和组成新图像利用 PCA 进行识别,作者称其方法为 (PC)<sup>2</sup>A。Songcan Chen<sup>[8]</sup>等改进了文[7]的方法,引进了非线性的积分投影与

原图像进行合成,生成一些新的图像,与原图像一起构成训练样本集,再用 PCA 进行识别,取得了高于文[7]的识别率。但文[7,8]生成虚拟样本的办法似乎少了一些,只利用了积分投影信息,并且图像中加入投影信息后,在什么情况下能提高识别率,仍有待进一步研究。文[9]的方法是对人脸图像分成左眼、右眼、鼻子、左嘴和右嘴 5 个区域,每个区域移动后增加样本数,利用 LDA 进行识别。它的困难在于准确的眼睛定位,这在有眼镜干扰、遮挡或眼睛闭合等情况下是很难进行的。

本文从两方面对这一问题进行探讨:一方面引进镜像变换和一些几何变换增加虚拟样本数量;另一方面利用二维主分量分析,抽取更利于分类的特征。本文提出了基于类间散度最大的二维主分量分析(2DPCAG<sub>b</sub>)方法。在 ORL 标准人脸库上进行的实验表明了本方法的有效性。

## 2 PCA、LDA 及 Fisherface 方法简介

设有一含有  $N$  个样本的集合  $F$ ,  $F$  中每一样本  $X$  为  $n$  维向量,设模式类别有  $c$  个:  $\omega_1, \omega_2, \dots, \omega_c$ , 每类有样本  $n_i$  个,它们的总体散度矩阵  $S_t$  (即总体协方差矩阵)、类内散度矩阵  $S_w$  和类间散度矩阵  $S_b$  分别定义如下:

$$S_b = \sum_{i=1}^c P(\omega_i) (m_i - m_0)(m_i - m_0)^T \quad (1)$$

$$S_w = \sum_{i=1}^c P(\omega_i) E\{(X - m_i)(X - m_i)^T / \omega_i\} \quad (2)$$

$$S_t = S_b + S_w = E\{(X - m_0)(X - m_0)^T\} = \sum_{i=1}^N (X_i - m_0)(X_i - m_0)^T \quad (3)$$

<sup>\*</sup>) 本文得到国家自然科学基金 60472060 项目的资助。张生亮 博士研究生,研究方向为模式识别和图像处理;陈伏兵 博士研究生,研究方向为模式识别和机器学习;杨静宇 博士生导师,研究方向为模式识别和智能系统。

其中,  $P(\omega_i) = n_i/N$  为第  $i$  类训练样本的先验概率,  $m_i = E\{X/\omega_i\}$  为第  $i$  类训练样本的均值,  $m_0 = E\{X\} = \sum_{i=1}^c P(\omega_i)m_i$  为全体训练样本的均值。

由定义知,  $S_w, S_b, S_t$  都是非负定的对称矩阵, 都可以求出  $n$  个本征值及  $n$  个线性无关的本征向量。对人脸识别问题, 一般  $n$  很大, 可以利用奇异值分解定理求取  $N$  阶矩阵, 以减少计算量。设  $S_t$  的本征值为  $\lambda_i (i=1, 2, \dots, n)$ , 且  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$ , 相应的本征向量为  $u_i$ , 则对任一  $F$  中的样本  $x$  可表示为:  $x = \sum_{i=1}^n y_i u_i$  其中  $y_i = X^T u_i (i=1, 2, \dots, n)$ ,  $y = [y_1, y_2, \dots, y_n]^T$ 。选取  $y$  的前  $d$  个分量  $\hat{y} = [y_1, y_2, \dots, y_d]^T$  作为抽取出的特征进行识别, 这种方法称为主分量分析, 简称 PCA,  $\hat{y}$  通常称为主分量。如将本征向量  $u_i$  重新排列成原图像大小的矩阵, 就是本征脸 (Eigenfaces)。

Fisher 鉴别准则函数定义为(4)式, 另一等价的 Fisher 鉴别准则函数由(5)给出:

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

$$J(\varphi) = \frac{\varphi^T S_b \varphi}{\varphi^T S_t \varphi} \quad (5)$$

其中,  $\varphi$  为任一  $n$  维非零列矢量。

LDA 就是求取  $d$  个使得  $J_f(\varphi)$  或者  $J(\varphi)$  达到极大值的投影方向  $\varphi_i (i=1, 2, \dots, d)$ 。将样本  $X$  在这些方向投影进行特征抽取, 然后分类识别。选取使得目标函数  $J_f(\varphi)$  或者  $J(\varphi)$  达到最大值的矢量作为投影方向, 其物理意义是投影后的类间离散度与类内离散度的比值最大。统计不相关的鉴别分析 (ULDA) 在选取最佳鉴别矢量集时, 除要求 Fisher 准则函数取极大值外, 还要求各投影方向  $\varphi_i$  之间是关于  $S_t$  共轭正交, 即:  $\varphi_i^T S_t \varphi_j = 0 \quad \forall i \neq j, i, j=1, \dots, d$ 。ULDA 消除了各特征分量之间的相关性, 所以可取得比 LDA 更好的识别效果。

Fisherface 方法的本质是 PCA+LDA。因为人脸识别是一个高维小样本问题, 大多数情况下  $S_w$  是奇异的, 所以要先进行降维, 使得  $S_w$  非奇异, 然后再利用 LDA。Fisherface 就是先利用 PCA 将样本维数降到  $\leq N-c$ , 在新的样本空间类内离散度矩阵非奇异后, 再利用 LDA 做特征抽取和识别。

### 3 二维主分量分析的思想与方法

设  $X$  表示  $n$  维单位化的列向量, 图像投影的思想是将  $m \times n$  的图像矩阵  $A$  通过  $Y=AX$  的线性变换直接投影到  $X$  上, 于是得到一个  $m$  维列向量  $Y$ , 称之为图像  $A$  的投影特征向量。  $X$  的选取准则是使得投影后的特征  $Y$  具有更好的可分性。类似于 PCA, 设模式类别有  $c$  个:  $\omega_1, \omega_2, \dots, \omega_c$ , 每类有样本  $n_i$  个, 每个样本是  $m \times n$  矩阵。我们可得到图像总体散布矩阵  $G_t$ 、图像类内散布矩阵  $G_w$  和图像类间散布矩阵  $G_b$ :

$$G_b = \sum_{i=1}^c P(\omega_i) (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \quad (6)$$

$$G_t = E[(A - \bar{A})^T (A - \bar{A})] = \frac{1}{N} \sum_{i=1}^N (A_i - \bar{A})^T (A_i - \bar{A}) \quad (7)$$

$$G_w = \sum_{i=1}^c P(\omega_i) \frac{1}{n_i} \sum_{j=1}^{n_i} (A_j^{(i)} - \bar{A}_i)^T (A_j^{(i)} - \bar{A}_i) \quad (8)$$

$$\bar{A} = \frac{1}{N} \sum_{i=1}^N A_i \quad (9)$$

$$\bar{A}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} A_j^{(i)} \quad (A_j^{(i)} \in \omega_i) \quad (10)$$

其中,  $P(\omega_i)$  为第  $i$  类模式的先验概率, 一般取  $P(\omega_i) = 1/c$ 。  $\bar{A}_i$  为第  $i$  类模式的均值向量矩阵 ( $i=1, 2, \dots, c$ ),  $\bar{A}$  为模式总

体的均值矩阵。

Yang<sup>[2,3]</sup> 采用准则(11):

$$J_p(X) = \text{tr}(TS_x) = X^T G_t X \quad (11)$$

其中,  $TS_x$  表示投影特征  $Y$  的总体散布矩阵,  $\text{tr}$  表示取矩阵的迹。

最大化该准则的单位向量  $X$  称为最优投影轴, 其物理意义是: 图像矩阵在  $X$  方向上投影后所得特征向量的总体分散程度最大。事实上, 该最优投影轴即为图像总体散布矩阵  $G_t$  的最大本征值所对应的单位本征向量。一般说来, 在样本类别数较大的情况下, 单一的最优投影方向是不够的, 需要寻找一组满足标准正交条件且极大化准则函数(11)式的最优投影轴  $X_1, \dots, X_d$ 。由于准则函数(11)等价于

$$J_1(X) = \frac{X^T G_t X}{X^T X} \quad (12)$$

(12)式即为矩阵  $G_t$  的 Rayleigh 商。由矩阵论中 Rayleigh 商的极值性质知, 最优投影轴  $X_1, \dots, X_d$  可取为  $G_t$  的  $d$  个最大本征值所对应的标准正交的本征向量。具体地讲, 设  $G_t$  的本征值满足  $\lambda_1 \geq \dots \geq \lambda_d \geq \dots \geq \lambda_n$ , 且对应的标准正交的本征向量为  $X_1, \dots, X_d, \dots, X_n$ , 则  $d$  个最优投影轴取为  $X_1, \dots, X_d$ 。

根据我们的分析和计算, 使总体散度最大的并不一定能带来好的可分性。总体散度最大表示类间散度与类内散度的和取最大。不同类的样本之间的距离越大, 也就是类间散度越大, 可分性越好。相反, 类内散度越小, 可分性越好; 类内散度越大, 可分性越差。如果我们直接取类间散度最大, 理应比取总体散度最大有更好的可分性。同时  $G_b$  的计算量比  $G_t$  小,  $G_t$  的计算与训练样本的总数  $N$  有关, 而  $G_b$  的计算与类别  $c$  有关。

我们取如下的准则:

$$J_2(X) = \frac{X^T G_b X}{X^T X} \quad (13)$$

使得经过投影后的类间散度最大, 也即取  $G_b$  的最大的  $d$  个本征值对应的标准正交的本征向量为最优投影轴进行投影, 抽取特征。

• 特征抽取方法

设最优图像投影轴为  $X_1, \dots, X_d$ , 令  $Y_k = AK_k (k=1, 2, \dots, d)$ , 则得到一组图像投影特征向量  $Y_1, \dots, Y_d$ , 它们可合并为一个  $N_i = md$  维的向量作为  $A$  的整体投影特征, 公式如下:

$$Y = [Y_1, Y_2, \dots, Y_d] = A[X_1, X_2, \dots, X_d] \quad (14)$$

用于随后的分类识别。

• 图像重构

由特征抽取式(14)的逆过程, 可以简单地求出  $A$  的重构图像

$$\tilde{A} = [Y_1, Y_2, \dots, Y_d] * [X_1, X_2, \dots, X_d]^T = \sum_{k=1}^d Y_k X_k^T \quad (15)$$

### 4 增加虚拟样本

假设给定训练样本  $A$ ,  $A$  为  $m \times n$  的图像, 我们增加  $11$  幅虚拟样本。具体作法如下:

1) 首先求  $A(x, y)$  水平和垂直方向的投影积分及图像  $A$  的像素点灰度的和:

$$V(x) = \sum_{y=1}^n A(x, y) \quad H(y) = \sum_{x=1}^m A(x, y)$$

$$\text{SUMA} = \sum_{y=1}^n \sum_{x=1}^m A(x, y) \quad (16)$$

计算  $MP(x, y)$  以及  $P(x, y)$ ;

$$MP(x,y)=V(x) * H(y)/SUMA \quad (17)$$

$$P(x,y)=(A(x,y)+\alpha * MP(x,y))/(1+\alpha) \quad (18)$$

(18)式中  $\alpha=0.25$

图像  $P(x,y)$  的取值可能超出了  $[0,1]$ 。将  $P(x,y)$  归一化到  $[0,1]$ ，得第一个虚拟图像 A1:

$$A1(x,y)=(P(x,y)-\min_{x,y}(P(x,y)))/(\max_{x,y}(P(x,y))-\min_{x,y}(P(x,y))) \quad (19)$$

2)对原始图像 A 的每一点的灰度值取平方得到图像  $J(x,y)=A^2(x,y)$ 。将  $J(x,y)$  代替  $A(x,y)$  代入式(16)，得到二阶投影积分  $V2(x)$ 、 $H2(y)$  及  $SUMA2$ 。同样地，用下式得到  $MP2(x,y)$ :

$$MP2(x,y)=V2(x) * H2(y)/SUMA2 \quad (20)$$

由图像 A、 $MP1$  以及  $MP2$  生成另一个图像  $P2(x,y)$ :

$$P2(x,y)=(A(x,y)+\alpha * MP(x,y)+\beta * MP2(x,y))/(1+\alpha+\beta) \quad (21)$$

同样， $P2(x,y)$  的值也可能超出了  $[0,1]$ 。用式(19)的方法将  $P2(x,y)$  归一化到  $[0,1]$ ，得第二个虚拟图像 A2。式(21)中取  $\alpha=0.25$ 、 $\beta=1.5$ 。虚拟图像 A1、A2 的生成可参阅文[7,8]。

3)将图像 A1 做镜像对称变换，得虚拟图像 A3。

4)图像 A2 做镜像对称变换得虚拟图像 A4。

5)基于人脸是基本对称的<sup>[10]</sup>，将 A 以垂直中心轴做镜像变换，得到虚拟样本图像  $A5=A * M$ ， $M$  是反对角线为 1、其余元素为 0 的方阵。增加镜像图像，可以部分消除头部旋转对识别的影响。

6)将 A 旋转一个角度(如  $5^\circ$ )，得到图像 A6。这中间需要进行插值和剪切运算，A6 与 A 的大小应相同。一般来说，旋转后的图像比原图像大，超出原图像的部分值填 0。

7)将旋转后的图像 A6 做镜像变换，得到  $A7=A6 * M$ 。

8)将 A 向右、向下平移，得到图像 A8。

9)将 A 向左、向下平移，得到图像 A9。

10)将 A 按系数 0.9 缩小，空出的部分补 0，得到虚拟样本图像 A10。

11)将 A 按系数 1.1 放大，对四周进行剪切使其与原图大小相同，得到虚拟样本图像 A11。



图 1 从左向右依次为原图像 A、MP、A1、MP2 和 A2




图 2 从左向右依次为原始样本、虚拟样本 A1、A2、A3、A4、A5




图 3 从左向右依次为虚拟样本 A6、A7、A8、A9、A10、A11

## 5 实验

实验是在 ORL 标准人脸库上进行的。ORL 库包含 40 人的 400 幅人脸图像，每人 10 幅，其中有些图像是拍摄于不

同时期的；人的脸部表情和脸部细节有着不同程度的变化，比如笑或不笑、眼睛或睁或闭、戴或不戴眼镜；人脸姿态也有相当程度的变化，深度旋转和平面旋转可达  $20^\circ$ ；人脸的尺度也有多达 10% 的变化。图 4 是 ORL 人脸库中某一人 10 幅图像。




图 4 ORL 人脸库中的 10 幅图像

我们首先只取每个人的 1 个样本进行训练，如都取第  $i$  个( $i=1, \dots, 10$ )，相应每人剩余的 9 幅图像进行测试，40 个训练样本，360 个测试样本，用 PCA 抽取 39 个主分量，计算出识别正确率以后，再进行平均，结果列在表 1 中。本文都使用最近邻方法进行分类，距离度量使用欧氏距离。Wu 在文[7]中提出了  $(PC)^2A$ ，取至 Projection Combined Principal Component Analysis 的缩写，利用前面第 4 节的虚拟样本 A1 代替

原来的训练样本，仍用一个样本训练，其余样本用于识别。新的训练样本加入了投影积分的信息。我们抽取 39 个主分量，在 ORL 库上的实验结果列在表 1 中。从表 1 第三行看出，加入投影信息后的污染图像作为训练样本，文[7]平均识别率下降了 6.14%。

Chen Songcan 等在文[8]中对文[7]的方法进行了改进，提出了称为  $E(PC)^2A+$ 、 $E(PC)^2A1+$  及  $E(PC)^2A2+$  的方

表1 不增加样本时单样本识别的正确率

样本	1	2	3	4	5	6	7	8	9	10	平均
PCA	71.11	71.39	73.06	67.78	67.78	64.17	72.50	70.83	70.56	66.11	69.5
(PC) <sup>2</sup> A	60.28	65.00	63.89	60.28	60.28	60.00	65.28	67.78	67.78	63.06	63.36

法。其中 E(PC)<sup>2</sup>A+ 利用每人的一个原始训练样本 A 及虚拟样本 A1 进行训练, 每人的其余样本用于识别。E(PC)<sup>2</sup>A1+ 是利用每人的一个原始训练样本 A、虚拟样本 A1、A2 及 A12(原图像的每一像素灰度值开方后形成新的图像 J(X, Y) = (√A(X, Y)), 用与生成 A2 同样的方法, 由(16)式、(20)式等生成 A12)进行训练。E(PC)<sup>2</sup>A2+ 方法与 E(PC)<sup>2</sup>A1+ 不同的是采用的虚拟样本 A2 不同, 见文[8]。主分量的个数选

取原则为: 使得  $\theta \geq 0.95$ 。

$$\theta = \frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^N \lambda_i} \quad (22)$$

我们在 ORL 库上进行了实验, 结果列在表 2 中。E(PC)<sup>2</sup>A+ 所用的训练样本为 80 个, E(PC)<sup>2</sup>A1+ 与 E(PC)<sup>2</sup>A2+ 所用的训练样本为 160 个。从识别结果来看, 文[8]中的三种方法差别不大, 识别效果都不如表 1 中的 PCA。

表2 文[8]中的增加样本时单样本识别的正确率

样本	1	2	3	4	5	6	7	8	9	10	平均
E(PC) <sup>2</sup> A+	69.72	69.44	71.94	67.22	65.56	60.56	71.11	68.33	66.67	63.61	67.42
E(PC) <sup>2</sup> A1+	70.56	69.17	70.83	68.06	65.00	61.67	71.11	68.33	68.33	63.89	67.69
E(PC) <sup>2</sup> A2+	70.28	69.17	71.39	67.22	65.00	62.22	71.39	68.61	66.94	63.33	67.56

我们用第 4 节的方法对每人的单个训练样本增加 11 个虚拟样本, 与原训练样本共 12 个图像做训练, 在 ORL 库中, 其余 9 幅图像作为测试样本。这样, 共有 480 幅训练样本、360 幅测试样本, 实验结果列在表 3 中。PCA 使用总体散布矩阵 S<sub>t</sub> 的前 d 个最大非零特征值对应的特征向量做投影方向, 使得对应的  $\theta \geq 0.95$ 。2DPCAG<sub>b</sub> 为使用 G<sub>d</sub> 的最大的 3 个本征值对应的标准正交的本征向量为最优投影轴, 3 个最大本征值对应的  $\theta \geq 0.85$ , 利用式(14)抽取特征。2DPCAG<sub>t</sub> 为使用 G<sub>t</sub> 的前 d 个最大特征值计算最佳投影轴。这里为和 2DPCAG<sub>b</sub> 进行比较, 也取 d=3, 识别结果列在表 3 中。

在这里 N-c=440, 我们将训练样本从 10304 维压缩到 400 维, 然后利用 LDA 选取 39 个鉴别矢量集进行特征抽取, 识别结果列在表 3 中。

下面的实验是在不加入有投影信息的虚拟样本的情况下进行的, 其余情况与表 3 所采用的方法相似。我们在 ORL 库中每人选取一个训练样本, 再加入虚拟样本 A5、A6、A7、A8、A9、A10 和 A11, 共 320 个训练样本, 360 个测试样本, 结果列在表 4 中。其中 Fisherface 第一步用 PCA 将样本维数压缩到 280 维, 然后用 LDA 选取 39 个鉴别矢量集进行识别。二维 PCA 仍取 3 个最优投影轴。PCA 仍然取使得  $\theta \geq 0.95$  的 d 个主分量。计算结果列在表 4 中。

Fisherface 的本质是 PCA+LDA, 先做 PCA 的目的是为了在压缩后, 样本的类内散布矩阵非奇异, 使 LDA 可以进行。

表3 增加 11 个虚拟样本时单样本识别的正确率

样本	1	2	3	4	5	6	7	8	9	10	平均
PCA	71.39	70.56	73.89	72.50	68.89	68.61	71.94	75.83	72.50	71.11	71.72
2DPCAG <sub>b</sub>	72.78	76.67	79.17	73.33	73.06	71.39	76.39	77.22	77.78	75.00	75.28
2DPCAG <sub>t</sub>	73.61	74.44	76.11	70.28	69.72	71.39	72.22	77.22	75.56	73.06	73.36
Fisherface	50.83	51.11	50.56	46.94	50.56	45.00	49.44	49.44	46.67	46.94	48.75

表4 增加 7 个虚拟样本时单样本识别的正确率

样本	1	2	3	4	5	6	7	8	9	10	平均
PCA	70.83	71.67	74.17	72.78	69.72	69.17	72.78	76.39	74.17	70.28	72.20
2DPCAG <sub>b</sub>	73.33	74.44	78.33	74.44	73.33	71.39	75.56	75.83	77.50	75.28	74.94
2DPCAG <sub>t</sub>	73.33	75.28	75.83	70.83	70.56	71.67	72.50	76.94	75.56	73.06	73.56
Fisherface	67.22	68.89	73.06	68.89	65.28	65.83	65.83	66.94	69.17	66.39	67.75

分析与总结 从表 3 和表 4 可以看出, 对一个样本的情况, 文[6]的 Fisherface 方法并不能取得好的识别效果。在这种情况下, 尽管增加一些虚拟样本可以使得 S<sub>0</sub> 非奇异, 但因增加的虚拟样本仍然集中在原训练样本周围, 所以要求类内散度最小, 没有多少意义。在图像中加入积分投影信息是文[7,8]所使用的方法。从 1~4 表格对应的计算结果可以看出, 此法在 ORL 人脸库上对提高识别率作用不大, 这可能与 ORL 人脸库中人脸图像变换比较大有关, 而文[7,8]的实验是在训练和测试样本都是正面图像上得到的。

呈 m<sup>2</sup> 级增长, 这是必须考虑的问题。而二维方法可以克服因增加虚拟样本带来的计算量增长问题, 因为 2DPCA 产生矩阵 G<sub>b</sub>、G<sub>t</sub> 的阶数=图像的列数, 对 ORL 库是 92 阶矩阵, 并不随虚拟样本数增加而增加。所以, 相比 PCA、Fisherface 等一维方法, 2DPCA 有明显的优势。

增加虚拟样本会使训练样本数量成倍地增长, 计算量是否可行呢? 对一维方法(如 PCA、LDA 等)确实有这个顾虑, 因为散步矩阵的阶数 m=min{训练样本数 N, 向量维数 n}。随着矩阵阶数 m 的增加, 计算特征值和特征向量的计算量将

计算结果表明, 同样是二维 PCA, 我们所提出的基于类间散度最大的 2DPCAG<sub>b</sub> 的识别率好于文[2]的以总体散度取最大的 2DPCAG<sub>t</sub>。表 3 中都取 3 号样本作为训练样本时, 识别率达到 79.17%, 平均也有 75.28% 的识别率。从计算量的角度考虑, 2DPCAG<sub>b</sub> 的计算量也是最小的。

我们从表中可以看出, 单样本选择的序号不同, 识别率也不同, 这其中的原因我们将进一步研究。还有, 如何由一幅图像得到头部姿态改变后的近似图像, 也是未来研究的方向。

参考文献

- 1 边肇祺,张学工. 模式识别(第二版)[M]. 北京:清华大学出版社,2000
- 2 Yang Jian, Zhang D, Yang Jing-Yu, et al. Two-Dimensional PCA, A New Approach to Appearance-Based Face Representation and Recognition [J]. IEEE transaction on Pattern Analysis and Machine Intelligence, 2004, 26(1)
- 3 杨健. 线性投影分析的理论及算法及其在特征抽取中的应用: [学位论文]. 南京:南京理工大学, 2002
- 4 Belhumeur P N, et al. Eigenfaces vs. Fisherfaces, Recognition Using Class Specific Linear Projection [J]. IEEE Transactions on PAMI, 1997, 19(7)
- 5 金忠,杨静宇,陆建峰. 一种具有统计不相关性的最优鉴别矢量集 [J]. 计算机学报, 1999, 22(10)

- 6 Shan Shiguang, et al. Extended Fisherface for Face Recognition from a Single Example Image Per Person [C]. IEEE International Symposium on Circuits and Systems, 2002, 2
- 7 Wu Jianxin, Zhou Zhi-Hua. Face recognition with one training image per person [J]. Pattern Recognition Letters, 2002, 23: 1711~1719
- 8 Chen Songcan, Zhang Daoqiang, Zhou Zhi-Hua. Enhanced (PC)<sup>2</sup>A for face recognition with one training image per person [J]. Pattern Recognition Letters, 2004, 25: 1173~1181
- 9 Huang Jian, Yuen Pong C, Chen Wen-Sheng, et al. Component-based LDA Method for Face Recognition with One Training Sample [C]. Proceedings of the IEEE International Workshop on Analysis and Modeling of Faces and Gestures (AMFG'03)
- 10 杨琼,丁晓青. 对称主分量分析及其在人脸识别中的应用 [J]. 计算机学报, 2003, 26(9)

(上接第 224 页)

距离设置为  $d$ , 裁剪的人脸大小为  $2d \times 2d$  的正方形。将标准人眼距离设为 128, 则根据  $d$  与 128 之间的比例可计算出人脸缩放的比例。




图 1 具有角度及表情变化的人脸<sup>[10]</sup>

图像训练集有两个:一个是类内训练集,另一个是类间训练集。类内训练集包含了 50 个人,每人两张不同表情的照片。利用类内训练集计算类内特征值和特征向量。类间训练

集中包括 100 张不同人的照片,利用类间训练集计算类间特征值和特征向量。对应于两个训练集,利用二维 PCA 算法构造了两个人脸空间。对于待识别的人脸,需要分别计算其在两个人脸空间内的投影,即类内投影和类间投影。使用的具体算法如第 2.3 节所述。特征向量选取了 10 个。

算法用 MATLAB 语言实现,实验中比较了经典一维 PCA、二维 PCA、统计二维 PCA 算法的识别率及识别一张人脸所需的时间。选用的人脸样本分为三种情况:标准表情的正面人脸;标准人脸和表情变化的人脸;标准人脸、表情变化、角度变化的人脸。表 1 给出了实验数据。表中的时间指的是平均时间,单位为秒。由表 1 看出,由于标准 PCA 方法对正脸的识别率很高,因此识别标准正脸(如图 1(c)所示)时三种算法的识别率一致,都能够达到 100%;但加入了表情及角度变化的人脸后(如图 1(a)、(b)、(d)所示),二维 PCA 和一维 PCA 的识别率受到较大的影响,而统计二维 PCA 方法的识别率只是稍有下降。这是由于新算法在识别的过程中考虑到了人脸的类内差别和类间差别,计算时使用了两个人脸空间。而标准二维 PCA、标准一维 PCA 都只考虑了不同人脸之间的差别,所以容易将具有不同表情的同一人脸也识别为不同的人脸。

表 1 经典一维 PCA、二维 PCA、统计二维 PCA 算法的识别率比较

样 本 \ 算 法	一维 PCA		二维 PCA		统计二维 PCA	
	识别率	时间	识别率	时间	识别率	时间
标准正脸	100%		100%		100%	
标准正脸,表情变化	68.18%	16s	80.3%	7s	95.08%	11s
标准,表情、角度变化	51.14%		60.23%		72.44%	

实验结果表明,本文的算法对光照、表情及角度变化的人脸识别率高、计算简单、速度快。但提取侧面人脸图像时,由于只可得到一只眼睛的中心点,因此第 3 节的图像归一化方法不太适用,这在很大程度上影响了识别率。因此,设计对归一化不敏感的识别算法是下一步的工作目标。

**结论** 本文介绍了一种可用于不同表情、角度的人脸识别方法。首先,利用二维 PCA 方法计算训练集人脸的特征值和特征向量,其中包括类内特征向量、类间特征向量。然后将待检测人脸向这两个空间投影。最后,设计了基于最大后验概率的分类器进行人脸识别,使用的模型符合高斯分布。

由于本文的算法基于 PCA,因此将其与二维 PCA 方法、一维 PCA 方法进行了比较。实验表明,本文的算法识别率高、计算简单、速度快,具有明显的优越性。这是由于该算法集中了两个优点:第一,利用了二维 PCA 方法计算简单、速度快的特点;第二,利用了统计的方法提高识别率。

参考文献

- 1 赵力庄,高文,陈熙霖. Eigenface 的变维分类方法及其在表情识别

- 中的应用. 计算机学报, 1999, 22(6): 627~633
- 2 Chellappa R, Wilson C, Sirohey S. Human and Machine Recognition of Faces; A Survey. Proc IEEE, 1995, 83(5): 705~740
- 3 Samal A, Iyengar P. Automatic Recognition and Analysis of Human Faces and Facial Expressions; A Survey. Pattern Recognition, 1992, 25: 65~77
- 4 刘小军,王东峰,张丽飞,等. 一种基于奇异值分解和隐马尔可夫模型的人脸识别方法. 计算机学报, 2003, 26(3): 340~344
- 5 Kim Tae-Kyun, Kim Hyunwoo, Hwang Wonjun, et al. Independent Component Analysis in a Facial Local Residue Space. CVPR' 2003
- 6 于兵,金连甫,陈平. 基于特征运动的人脸表情识别. 中国图像图形学报, 2002, 7(11): 1139~1143
- 7 Moghaddam B, Pentland A. Probabilistic Visual Learning for Object Representation. IEEE trans on PAMI, 1997, 19(7): 696~710
- 8 Yang Jian, Zhang D, Frangi F, et al. Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition. IEEE trans on PAMI, 2004, 26(1): 131~137
- 9 Moghaddam B. Principal Manifolds and Probabilistic Subspaces for Visual Recognition. IEEE trans on PAMI, 2002, 24(6): 780~788
- 10 CVL FACE DATABASE. <http://www.lrv.fri.uni-lj.si/facedb.html>
- 11 边肇祺,张学工. 模式识别. 第二版. 北京:清华大学出版社, 2001