

# 利用两类投影方法进行特征融合的人脸识别

张生亮，徐 勇，杨 健，杨静宇

(南京理工大学计算机学院，南京 210094)

**[摘要]** 提出了利用两类投影抽取特征、用并行策略融合特征进行人脸识别的新方法。先用一维的基于向量的投影抽取一组特征，再用基于二维的图像投影的方法抽取一组特征，用复向量将样本的两组特征向量组合在一起，在复向量空间分析主分量 (CPCA)，抽取人脸图像的鉴别特征。在 FERET 人脸库上的实验结果表明，该方法的识别性能比用单个特征有 10% 左右的提高。

**[关键词]** 特征融合；线性鉴别分析 (LDA)；特征抽取；人脸识别

**[中图分类号]** TP391.4    **[文献标识码]** A    **[文章编号]** 1009-1742 (2006) 08-0050-06

## 1 引言

人脸识别是当前图像工程领域的四大研究热点之一<sup>[1]</sup>。究其原因，一是人脸识别有非常广泛的应用前景；二是计算机分析识别人脸图像有许多困难。一方面由于人脸之间的相似性，不同人的人脸图像在图像空间中距离非常接近；另一方面，同一个人的人脸图像又有光照、姿态、表情、年龄等许多变化，使得人脸图像的特征抽取、分类识别特别复杂。人脸图像的维数一般达几千或上万维，抽取有效的特征是非常关键。现有的代数特征抽取方法绝大多数采用一维的方法，即首先将图像转换为一维向量，再用主分量分析 (PCA)、Fisher 线性鉴别分析 (LDA)、Fisherfaces 或核主分量分析 (KPCA) 等方法抽取特征，然后用适当的分类器分类。针对一维方法维数高、计算量大，协方差矩阵常常是奇异矩阵等不足，文献[2, 3]中提出的二维的图像特征抽取方法，计算量小，协方差矩阵一般是可逆的，并且识别率较高。

不同方法抽取的特征反映了模式对象在不同标准下的分类能力。在一种特征空间很难区分出来的

样本，可能在另一特征空间里可以很容易地分开。因此，将不同方法抽取的特征有机地结合在一起，就可能得到更好的分类性能。以前的特征抽取方法是一维的或是二维的，还未见组合这两类特征的融合方法。笔者用一维和二维方法抽取两组特征，用并行方法将两组特征组合成复向量，用复主分量分析 (CPCA) 提取融合特征<sup>[4]</sup>，然后进行人脸识别。

## 2 两种特征抽取方法

两种特征抽取方法：一种是传统的将图像转换成一维向量，然后用 PCA，LDA 或 Fisherfaces 等方法抽取出一组特征；另一种方法是将图像看成一个矩阵，直接进行投影分析，抽取出特征向量。

### 2.1 Fisher 线性鉴别分析 (LDA)

设向量样本集  $\{X\}$ ，所属类别分别为  $\omega_1, \omega_2, \dots, \omega_c$ ，总类别数为  $C$ 。LDA<sup>[5, 6]</sup> 的目标是寻找一组线性变换，使得每类的类内离散度最小，并且使类间的离散度达到最大。LDA 是模式识别中最有效的特征抽取方法之一，使用 Fisher 准则函数，其定义为

$$J(W) = \arg \max_W |W^T S_b W| / |W^T S_w W| \quad (1)$$

[收稿日期] 2005-04-03；修回日期 2005-06-01

[基金项目] 国家自然科学基金资助项目 (60472060)

[作者简介] 张生亮 (1964-)，男，山西文水县人，南京理工大学博士生，研究方向为模式识别和图像处理

其中类间散度矩阵  $S_b$ 、类内散度矩阵  $S_w$  和总体散度矩阵  $S_t$  分别为

$$S_b = \sum_{i=1}^c P(\omega_i) (m_i - m_0)(m_i - m_0)^T \quad (2)$$

$$S_w = \sum_{i=1}^c P(\omega_i) E\{(X - m_i)(X - m_i)^T / \omega_i\} \quad (3)$$

$$S_t = S_b + S_w \quad (4)$$

$m_i$  为类别  $\omega_i$  的均值,  $P(\omega_i)$  为其先验概率,  $m_0$  为样本总体均值。求解准则函数式(1) 的  $d$  个最佳投影轴等同于求解广义特征方程

$$S_b \boldsymbol{\varphi} W = \lambda S_w \boldsymbol{\varphi} \text{ 或 } S_b \boldsymbol{\varphi} = \lambda S_t \boldsymbol{\varphi} \quad (5)$$

的  $d$  个最大本征值的本征向量  $\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_d$ 。

特征抽取  $Y$  为

$$\begin{aligned} Y = (y_1, y_2, \dots, y_d)^T = \\ (\boldsymbol{\varphi}_1^T X, \boldsymbol{\varphi}_2^T X, \dots, \boldsymbol{\varphi}_d^T X)^T \end{aligned} \quad (6)$$

讨论  $S_w$  奇异情况下求解最优投影轴的文章很多, 如 Fisherfaces 方法<sup>[5]</sup>, 其本质是 PCA + LDA。Fisherfaces 先利用 PCA<sup>[6, 7]</sup> 将样本维数降到  $\leq N - C$ ,  $N$  为训练样本的个数,  $C$  表示样本的类别数, 在新的样本空间  $S_w$  非奇异后, 再利用 LDA 将维数压缩为  $d$  ( $d \leq C - 1$ ) 维, 作为抽取出的特征进行模式分类。

采用扩大样本集和对图像降维方法也可使类内散布矩阵为非奇异阵。

## 2.2 二维特征抽取方法 2DPCA

二维主分量分析 (2DPCA)<sup>[3]</sup> 不需要将图像转换为向量, 而是直接进行图像投影, 得到的特征是向量而不是系数。图像投影就是将  $m \times n$  的图像矩阵  $A$  通过  $Y = AX$  的线性变换直接投影到  $n$  维列向量  $X$  上, 得到一个  $m$  维列向量  $Y$ , 称为图像  $A$  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, 2DPCA 的鉴别矢量集取为图像总体散布矩阵  $G_t$  的  $d$  个最大本征值对应的本征向量。设模式类别有  $C$  个, 即  $\omega_1, \omega_2, \dots, \omega_C$ , 每类有样本  $n_i$  个, 每个样本是  $m \times n$  矩阵, 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  $G_b$ :

$$G_b = \sum_{i=1}^c P(\omega_i) (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \quad (7)$$

$$G_t = \frac{1}{N} \sum_{i=1}^N (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \quad (8)$$

$$G_w = \sum_{i=1}^c P(\omega_i) \frac{1}{n_i} \sum_{j=1}^{n_i} (\bar{A}_{ij} - \bar{A}_i)^T (\bar{A}_{ij} - \bar{A}_i) \quad (9)$$

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

其中  $P(\omega_i)$  为第  $i$  类模式的先验概率, 一般取  $P(\omega_i) = n_i/N$ ,  $\bar{A}_i$  为第  $i$  类模式的均值矩阵 ( $i = 1, 2, \dots, C$ ),  $\bar{A}$  为模式总体的均值矩阵。

2DPCA 也可以取  $G_b$  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, 一般可取得比用总体散度矩阵更好的识别率。同时,  $G_t$  的计算与训练样本的总数  $N$  有关, 而  $G_b$  的计算与类别数  $C$  有关,  $G_b$  的计算量比  $G_t$  小。

特征抽取方法:

设最优图像投影轴为  $X_1, \dots, X_d$ , 令  $Y_k = (\bar{A} - \bar{A}) X_k$  ( $k = 1, 2, \dots, d$ ), 则得到一组图像投影特征向量  $Y_1, \dots, Y_d$ , 将它们合并, 作为图像  $A$  的投影特征  $Y = [Y_1, \dots, Y_d]$ , 用于分类识别。

## 3 两组特征的融合策略

设同一个样本的用 2 种方法抽取出的特征向量分别为  $\alpha$  和  $\beta$ , 用复向量  $\gamma = \alpha + i\theta\beta$  ( $\theta > 0$ , 为加权系数) 来表示并行组合后的特征。若 2 组特征  $\alpha$  与  $\beta$  的维数不等, 低维的特征向量用零补足。例如,  $\alpha = (a_1, a_2, a_3)^T$ ,  $\beta = (b_1, b_2)^T$ , 则  $\gamma = (a_1 + ib_1, a_2 + ib_2, a_3 + i0)^T$  表示组合后的特征向量。二维方法抽取的特征  $Y$  与一维方法抽取出的特征一起组合时, 先将  $Y$  拉直成一个向量, 再进行相应的组合。

两组特征之间的值可能相差很大, 组合前应进行预处理。将特征样本  $\alpha$  与  $\beta$  分别进行标准化处理:  $Y = (X - \mu)/\sigma$ , 其中,  $X$  为  $n$  维特征样本,  $\mu$  为训练样本的均值向量,  $\sigma = \frac{1}{n} \sum_{j=1}^n \sigma_j$ ,  $\sigma_j$  为所有训练样本的第  $j$  个特征分量的标准差。

简单地取  $\theta = 1$ , 要取其最佳是比较困难的。一般考虑两点, 一是用单个特征  $\alpha$  或  $\beta$  的分类能力, 即取  $\theta = \beta$  或  $\theta = \alpha$ ; 二是  $\alpha$  与  $\beta$  的维数不等时, 令  $\delta$  表示特征  $\alpha$  与  $\beta$  的维数之比, 则可根据  $\delta$  是否大于 1 在区间  $(\delta, \delta^2)$  内或在  $(\delta^2, \delta)$  内选取  $\theta$ 。组合后的特征如果直接用于分类, 并不能提高识别率, 有时识别率还会降低。组合后的特征应当在复向量空间中再提取一次特征, 才能起到提高识别率的效果。

复向量空间是定义了内积的复向量空间，其内积和范数定义如下：

$$(X, Y) = X^H Y \quad \|X\| = (X^H X)^{1/2} \quad (11)$$

式中的  $H$  为共轭转置符号。

复特征融合：

在复空间中样本仍然用  $X$  表示， $m_0$  表示总体均值， $m_i$  表示第  $i$  类训练样本的均值，计算类间散度矩阵、类内散度矩阵和总体散度矩阵：

$$S_b = \sum_{i=1}^c P(\omega_i) (m_i - m_0)(m_i - m_0)^H \quad (12)$$

$$S_w = \sum_{i=1}^c P(\omega_i) E\{(X - m_i)(X - m_i)^H / \omega_i\} \quad (13)$$

$$S_t = S_b + S_w = E\{(X - m_0)(X - m_0)^H\} \quad (14)$$

由定义可知， $S_w$ ， $S_b$ ， $S_t$  均为 Hermite 矩阵，且非负定。由于是第二次特征抽取，所以一般  $S_w$ ， $S_t$  均为正定矩阵。用复主分量分析 (CPCA)<sup>[6]</sup> 计算  $S_t$  或  $S_b$  的  $d$  个最优投影方向，将复向量  $X$  在这些方向投影，抽取出最终的分类特征。

#### 4 FERET 人脸库上的实验与分析

实验是在较大的 FERET 人脸库<sup>[8]</sup> 的子库上进行的，该子库包含 200 个人的 1 400 幅图像（每人 7 幅），这些图像的文件名均包含了标识字符串：ba，bj，bk，be，bf，bd，bg。这些字符串标识了每幅图像的变化情形，如姿态、表情、光照等。bj 是表情变化，bk 是光照变化，bd，be，bf，bg 包含了姿态的变化 ( $\pm 15^\circ$ ,  $\pm 25^\circ$ )。在本实验使用已经裁剪好的 80 (80) 的图像。图 1 为 FERET 人脸库某人的 7 幅图像，下面对应的是相应文件中的标识符。

将图像用邻域均值的方法进行压缩，使其分别成为  $40 \times 40$  及  $20 \times 20$  的图像。这样对  $20 \times 20$  的人脸图像进行识别就不是高维小样本问题，本征值本征向量的计算不需要用奇异值分解定理。LDA 的计算中所遇到的矩阵是 400 阶的，不随样本数的增加而增加矩阵的阶数。这种降维的方法为处理几百上千人的大型的人脸识别提供了计算上的可能。许多实验表明，将人脸图像降低到合适的分辨率后，不但会提高运算速度，也会取得较高的识别率。为了消除光照强弱对识别的影响，对每幅降维后的图像作直方图均衡化处理。图 2 是压缩到  $40 \times 40$  及  $20 \times 20$  的分辨率，并进行直方图均化前后的图像对

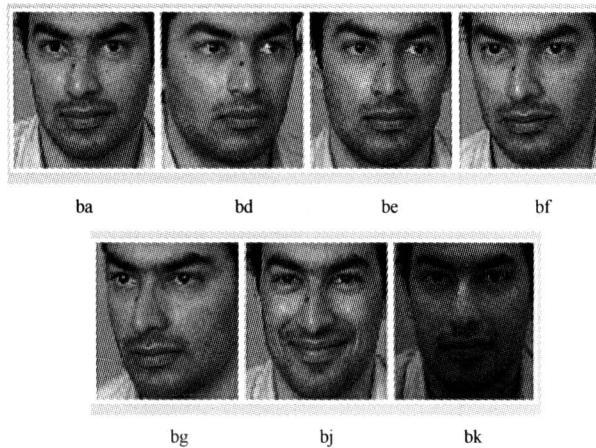


图 1 FERET 人脸库中经裁剪后的图像

Fig. 1 One person images in the FERET database after cropped well

比。可以看出降维后的图像用于分类仍然是合适的。直方图均化后的图像光照变化的影响明显减小。



图 2  $40 \times 40$  与  $20 \times 20$  分辨率图像及进行直方图均衡化后的比较

Fig. 2 The FERET images with resolution  $40 \times 40$  and  $20 \times 20$ ，and compared with its after histogram equalization

1 至 7 之间的整数分别对应图像文件含有标识符 ba，bd，be，bf，bg，bj，bk 的样本。在实验中，用随机程序产生 1 至 7 的排列，前 3 个数字对应的 3 幅图像作为训练样本，后 4 个数字对应测试样本。这样原始训练样本有  $200 \times 3 = 600$  个，测试样本的总数为  $200 \times 4 = 800$  个。

人脸都是基本对称的，每人只用 3 幅图像进行训练，显得训练样本不足。特别是考虑到姿态的变化，如果未包含某一方向的训练样本，抽取出特征后进行特征比对匹配时会产生出许多错误的分类。

例如, 只用向右旋转人脸图像训练, 而用向左旋转后的图像测试, 会增加出错的概率。通过增加镜像图像作为训练样本, 对提高有姿态变化的人脸识别效果显著。所以, 将每人的 3 个训练样本作镜像变换, 产生出 3 个镜像样本, 与原有的 3 个训练样本一起进行训练, 构成扩大的训练样本集。图像  $A$  的镜像 =  $AM$ ,  $M$  是一个与  $A$  的列数相同的方矩阵, 且反对角线上的元素为 1 其余元素都为零。这样共有 1 200 个训练样本。

首先用二维投影计算矩阵  $G_1$ , 取 6 个最佳投影轴, 提取 120 个特征, 作为第一组特征  $\alpha_1$ 。利用  $\alpha_1$  直接进行识别分类的方法, 称其为 2DPCA  $G_1$ 。用 LDA 也抽取 120 个特征, 作为第二组特征  $\beta$ 。加权系数取  $\theta = 1.0$ , 组合为  $\alpha_1 + i\beta$ 。在复向量空间中取 28 个主分量, 作 10 次实验, 结果见表 1 至表 4 中融合方法 1。再用二维投影计算矩阵  $G_b$ , 取 6 个最佳投影轴, 提取 120 个特征, 作为第一组特征  $\alpha_2$ 。利用  $\alpha_2$  直接进行识别的方法称为 2DPCA  $G_b$ 。 $\alpha_2$  与  $\beta$  组合为  $\alpha_2 + i\beta$ , 在复向量空间中由类间散布矩阵作为产生矩阵抽取 28 个主分量, 作 10 次实验, 识别结果见表 1 至表 4 中融合方法 2。实验中采用最近邻分类器。

表 1 在分辨率为  $20 \times 20$  的 FERET 人脸库上的实验结果

Table 1 The recognition rates (%) at the FERET database under  $20 \times 20$  resolution

训练样本	2DPCA $G_1$	LDA	融合方法 1	2DPCA $G_b$	融合方法 2
2, 7, 4	73.25	70.75	84.13	75.25	86.88
1, 2, 6	56.88	65.63	75.75	63.13	76.38
1, 2, 7	66.13	64.75	81.75	69.75	81.00
3, 4, 7	77.38	64.63	79.50	77.88	81.63
3, 6, 4	68.38	66.25	76.00	71.38	79.38
1, 3, 2	52.25	68.63	72.75	64.25	75.50
2, 7, 6	58.13	62.13	73.63	62.50	76.00
1, 3, 4	70.38	65.00	73.25	70.00	77.00
5, 1, 4	53.25	70.38	71.88	64.63	72.25
4, 5, 6	50.13	68.25	72.38	60.38	71.25
平均	62.62	66.64	76.10	67.92	77.73

复主分量分析取多少主分量  $d$  对识别率有一定影响, 但在一个相对大的区间内变化不大, 方差很小, 所以该方法具有很好的稳定性。对  $d$  取 20 至 70

之间, 用上面的 10 次抽取的样本进行了计算, 10 次的平均识别率稳定在 75.6% 至 77.8% 之间。随机取 3 个训练样本的 5 次实验针对  $d$  取 20 至 70 之间的不同值, 其识别率曲线图见图 3, 曲线基本平稳。

表 2  $40 \times 40$  分辨率的 FERET 库上的实验结果

Table 2 The recognition rates (%) at the FERET database under  $40 \times 40$  resolution

训练样本	2DPCA $G_1$	EFM	融合方法 1	2DPCA $G_b$	融合方法 2
2, 7, 4	73.50	62.88	88.00	78.38	88.00
1, 2, 6	58.13	58.75	77.88	64.88	76.13
1, 2, 7	69.25	54.38	80.75	70.88	81.38
3, 4, 7	77.25	61.63	85.13	81.63	84.75
3, 6, 4	68.75	62.13	80.50	74.13	80.63
1, 3, 2	55.00	67.75	79.00	66.00	78.75
2, 7, 6	59.63	53.13	79.00	63.63	76.88
1, 3, 4	71.50	63.25	78.25	72.88	78.00
5, 1, 4	57.25	70.38	74.63	66.75	73.00
4, 5, 6	53.00	65.13	73.63	62.50	72.88
平均	64.33	61.94	79.68	70.17	79.04

表 3  $80 \times 80$  分辨率的 FERET 人脸库(未进行光照标准化)上的实验结果

Table 3 The recognition rates (%) at the FERET database under  $80 \times 80$  resolution

训练样本	2DPCA $G_1$	EFM	融合方法 1	2DPCA $G_b$	融合方法 2
2, 7, 4	79.38	58.75	89.00	84.50	91.38
1, 2, 6	54.38	54.38	68.75	62.00	68.00
1, 2, 7	72.38	49.50	82.25	79.50	84.13
3, 4, 7	81.00	55.00	84.00	83.50	86.88
3, 6, 4	65.50	55.13	68.88	65.75	71.13
1, 3, 2	53.88	60.25	70.25	64.63	71.63
2, 7, 6	70.13	49.88	80.88	75.75	82.88
1, 3, 4	66.50	56.50	68.88	65.88	69.12
5, 1, 4	52.75	58.13	69.12	59.00	67.38
4, 5, 6	51.00	58.38	69.25	57.88	67.88
平均	64.69	55.59	75.13	69.84	76.04

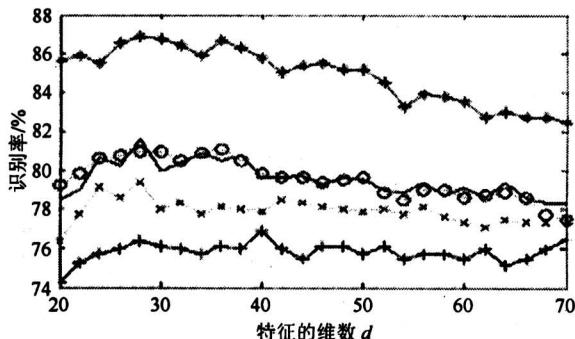
图像分辨率为  $40 \times 40$  或  $80 \times 80$  时, 一维的类内散度矩阵是奇异的, 用 LDA 前要先用 PCA 降维。这是和表 1 中不同的地方。使用增强 Fisher 线性鉴别法<sup>[9]</sup> (EFM, enhanced Fisher linear discriminant) 抽

**表 4  $40 \times 40$  分辨率 FERET 人脸库上的 10 次实验的平均结果**

Table 4 The ten times average recognition rates (%) at the FERET database under  $40 \times 40$  resolution

图像分辨率	2DPCA $G_1$	EFM	融合方法 1	2DPCA $G_b$	融合方法 2
$40 \times 40$	64.33 (65.49)	61.94 (39.85)	79.68 (67.49)	70.17 (63.97)	79.04 (66.09)

注：括号中的数是不加入 3 个镜像样本的识别率，括号外为加入镜像样本后的识别率。



**图 3 复主分量分析抽取不同的特征个数对识别率的影响**

Fig.3 Five CPCPA Recognition Rates curves with different feature numbers

取特征。C. J. Liu 等人认为，PCA 过小的特征值含有较多的干扰信息，不利于随后的鉴别处理，故建议在 PCA 阶段只保留少量的较大特征值对应的主要分量信息，舍弃大部分的次要分量信息。实验中先用 PCA 将图像压缩到 400 维，再用 LDA 抽取 199 个特征，与 2DPCA 抽取的特征进行融合后计算识别率，结果列在表 2、表 3 中。对于二维 PCA 的投影轴个数，在人脸图像分辨率为  $40 \times 40$  时，取 5 个最优投影轴；在图像分辨率为  $80 \times 80$  时，取 3 个最优投影轴。表 2 中融合后的特征数取  $d = 28$ ，表 3 中融合后的特征数取  $d = 50$ 。

从 3 个实验的数据对比可见，二维算法就单个识别率而言取类间散度最大的 2DPCA  $G_b$  好于以总体散度最大的 2DPCA  $G_1$ ，但是融合后的效果都有很大提高，且基本相当。这说明 2DPCA 与一维 LDA 的特征之间有互补性，融合后都能提高识别率。三种不同分辨率的实验表明，在  $40 \times 40$  的分辨率下，取得的识别率最高，这说明合适的图像分辨率对识别率也有影响。

一个自然的想法是二维算法是否可用二维线性

鉴别分析（2DLDA）与一维 LDA 进行融合。经过实验发现，2DLDA 在这个 200 人的人脸库上的识别率很低，只有 40% 左右，这说明 2DLDA 的识别性能不一定好于 2DPCA。2DLDA 与 LDA 融合后的识别率反而低于 LDA 本身的识别率。这说明 LDA 推广到 2DLDA 后，随样本类别数的增多它的识别率下降的很快，它的鉴别能力和适用场合有待进一步研究。不加入镜像样本也进行了实验，结果见表 4，括号中为不加入镜像样本的数据。EFM 提高识别率 22.09%，两种融合方法分别提高 12.19% 和 12.95%，加入镜像样本是有效的。

## 5 结论

提出一种将基于向量提取的特征与基于二维的图像投影提取的特征相融合的特征抽取方法，一方面提高了识别性能，另一方面减少了所需抽取的特征数量。在 FERET 人脸库上用 3 种不同的分辨率所做的实验，验证了该方法的有效性。该方法虽然是在人脸库上进行，但其应用不仅仅限于人脸识别，对其他类似的图像分类也有实际的应用价值。所使用的对图像降维和加镜像样本的方法，有助于提高其他人脸识别算法的识别率。此外，所用的算法计算量小，特别是 2DPCA 不随样本数的增加而增加计算量，为实际中处理大样本集的人脸识别问题提供了参考。

## 参考文献

- [1] 章毓晋. 中国图像工程及当前的几个研究热点 [J]. 计算机辅助设计与图形学学报, 2002, 14(6): 489 ~ 500
- [2] Liu Ke, Cheng Yongqing, Yang Jingyu, et al. Algebraic feature extraction for image recognition based on an optimal discriminant criterion [J]. Pattern Recognition, 1993, 26(6): 903 ~ 911
- [3] Yang Jian, Zhang David, Yang Jingyu, et al. Two-dimensional PCA a new approach to appearance-based face representation and recognition [J]. IEEE PAMI, 2004, 26(1): 131 ~ 137.
- [4] Yang Jian, Yang Jingyu, Zhang David, et al. Feature fusion: parallel strategy vs. serial strategy [J]. Pattern Recognition, 2003, 36: 1369 ~ 1381
- [5] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. IEEE Trans PAMI, 1997, 19(7): 711 ~ 720

- [ 6 ] 杨 健. 线性投影分析的理论与算法及其在特征抽取中的应用 [D]. 南京: 南京理工大学, 2002.
- [ 7 ] 边肇祺, 张学工. 模式识别 (第二版) [M]. 北京: 清华大学出版社, 1999. 212 ~ 229.
- [ 8 ] Phillips P J. The Facial Recognition Technology (FERET) Database [DB/OL]. [http://www.itl.nist.gov/iad/humanid/feret/feret\\_master.html](http://www.itl.nist.gov/iad/humanid/feret/feret_master.html), 2004
- [ 9 ] Liu Chengjun, Wechsler H. A shape-and texture-based enhanced fisher classifier for face recognition [J]. IEEE Trans Image Processing, 2001, 10(4): 598 ~ 608

## A Face Recognition Based on Fusion Features Extraction From Two Kinds of Projection

Zhang Shengliang, Xu Yong, Yang Jian, Yang Jingyu

(School of Computer Science, Nanjing University of Science & Technology, Nanjing 210094, China)

**[Abstract]** A novel face recognition algorithm based on two kinds of projection is presented in this paper. First, the two dimension principal component analysis (2DPCA) is used to extract one group of features, denoted by  $\alpha$ . Second, the fisher linear discriminant analysis (LDA), or fisherfaces, is used for extracting another group of features, denoted by  $\beta$ . After being standardized, the two kinds of features are combined together in the form of the complex vector  $\alpha + i\beta$ . Then the fusion features in the complex feature space is extracted by using complex PCA (CPCA). The proposed algorithm is evaluated by using the FERET face database at three different resolutions. The experimental results indicate that the proposed method can achieve about 10% higher recognition accurate rate than 2DPCA and LDA, while only using 28 features for each sample.

**[Key words]** feature fusion; linear discriminant analysis (LDA); feature extraction; face recognition

(cont. from p.38)

## Research and Development of Highly Immersive Multi-projection Virtual Environment Systems

Jia Qingxuan<sup>1</sup>, Song Jingzhou<sup>1,2</sup>, Sun Hanxu<sup>1</sup>, Gao Xin<sup>2</sup>, Yao Fusheng<sup>2</sup>

(1. School of Automation, Beijing University of Posts & Telecommunications, Beijing 100876, China;  
2. School of Mechanical Engineering & Automation, Beihang University, Beijing 100083, China)

**[Abstract]** This paper presents a framework for a highly immersive multi-projection virtual environment system, and addresses the key problems for building the system such as stereo display, graphics partition, render synchronization, geometric calibration, color calibration, etc.. Using networked PCs, low cost projectors and low capability network equipment, a five-channel 220 degree view field multi-projection virtual environment application system is built. Its coherent and highly immersive display effect validates the method.

**[Key words]** multi-projection; render synchronization; stereo display; geometric calibration; color calibration