

# 基于多类最大散度差的人脸表示方法<sup>1)</sup>

宋枫溪<sup>1,2</sup> 杨静宇<sup>3</sup> 刘树海<sup>2</sup> 张大鹏<sup>4</sup>

<sup>1</sup>(哈尔滨工业大学深圳研究生院 深圳 518055)

<sup>2</sup>(炮兵学院 合肥 230031)

<sup>3</sup>(南京理工大学 南京 210094)

<sup>4</sup>(香港理工大学)

(E-mail: fx\_song@sina.com)

**摘要** 将用于两类分类的最大散度差鉴别准则推广为多类最大散度差鉴别准则,并建立了基于该准则的一种新的人脸表示方法.基于多类最大散度差鉴别准则的人脸表示方法有效避免了传统鉴别分析方法在人脸特征提取时通常面临的小样本模式识别问题.在国际标准人脸图像数据库 ORL、Yale 以及 FERET 上的实验结果表明,与 Fisherfaces、Eigenfaces、正交补空间、零空间等人脸特征提取方法相比,新的人脸表示方法具有一定的优势.

**关键词** 最大散度差, Fisher 鉴别准则, 特征向量, 特征提取, 人脸识别  
中图分类号 TP39

## Face Representation Based on the Multiple-class Maximum Scatter Difference

SONG Feng-Xi<sup>1,2</sup> YANG Jing-Yu<sup>3</sup> LIU Shu-Hai<sup>2</sup> ZHANG David<sup>4</sup>

<sup>1</sup>(Shenzhen Graduate School, Harbin Institute of Technology, Shenzhen 518055)

<sup>2</sup>(Artillery Academy, Hefei 230031)

<sup>3</sup>(Nanjing University of Science and Technology, Nanjing 210094)

<sup>4</sup>(Hong Kong Polytechnic University)

(E-mail: fx\_song@sina.com)

**Abstract** In this paper we extend the maximum scatter difference discriminant criterion which is proposed for binary classification to the multiple-class maximum scatter difference discriminant criterion. Based on this new criterion we establish a novel face representation method. The facial feature extraction method based on the multiple-class maximum scatter difference discriminant criterion effectively avoids the small sample size problem which always brings troubles to conventional discriminant analysis methods when they are applied to face recognition tasks. Experimental results conducted on international benchmark datasets such as ORL, Yale, and FERET face image databases demonstrate that the novel face representation method is promising in comparison with Fisherfaces, eigenfaces, orthogonal complimentary space method, and null space method.

**Key words** Maximum scatter difference, Fisher discriminant criterion, eigenvectors, feature extraction, face recognition

## 1 引言

人脸识别是模式识别领域中的一个重要研究课题,近年来受到了学者们的广泛关注,成为一个异常活跃的研究方向<sup>[1~13]</sup>.就静态的人脸(图像)识别而言,大致有两种不同的研

1) 国家自然科学基金(60472060, 60473039)资助

Supported by National Natural Science Foundation of P. R. China (60472060, 60473039)

收稿日期 2004-11-4 收修改稿日期 2006-1-10

Received November 4, 2004; in revised form January 10, 2006

究途径. 一种是设法构造出各种复杂的人脸分类器, 使得这些分类器能够根据训练样本的特点以及识别任务的需要自动抽取人脸图像中的鉴别特征并用于分类. 这种研究途径的重点是分类器的设计与构造. 以这种方式应用于人脸识别的分类算法, 除了近年来宋枫溪等人陆续提出的大间距线性投影<sup>[1]</sup>、最大散度差<sup>[2]</sup>和最小模最小平方误差<sup>[3]</sup>等分类算法以外, 常见的有神经网络<sup>[4]</sup>和支持向量机<sup>[5]</sup>两种.

另外一种研究途径是首先将人脸图像对应的高维输入向量转化为能反映其本质特点的低维特征向量, 然后运用最近邻、最小距离等简单分类器对这些特征向量进行学习和分类, 从而将不同类别的人脸图像区分开来. 这种研究途径的重点是人脸鉴别特征的有效提取. 人脸鉴别特征的提取方法通常分为两大类, 基于几何特征<sup>[6]</sup>的提取方法和基于代数特征的提取方法. 人脸图像的几何特征受光照、表情、尺寸、姿态等因素的影响很大, 通常难以抽取, 基于代数特征的人脸特征提取方法因而成为当前统计模式识别领域中的主流方法.

基于代数特征的人脸特征提取方法将人脸图像看成是高维欧氏空间中的一个向量, 通过构造恰当的线性或非线性变换, 将高维输入向量压缩到一个低维特征向量, 从而得到人脸图像的一个简约表示. 从高维输入空间到低维特征空间的线性变换可以由变换矩阵来唯一确定, 不同的变换矩阵将导致不同的特征提取方式. 迄今为止, 人们已经找到多种人脸特征提取方法, 如 Turk 和 Pentland 提出的基于主成分分析 (Principal component analysis, 简记为 PCA) 的 Eigenfaces<sup>[7]</sup>, Belhumeur 等提出的基于 Fisher 线性鉴别 (Fisher linear discriminant, 简记为 FLD) 的 Fisherfaces<sup>[8]</sup>, Bartlett 等提出的基于独立成分分析<sup>[9]</sup>以及杨健等提出的基于 2 维主成分分析<sup>[10]</sup>的人脸特征提取方式等等.

严格讲, Fisherfaces 不是一种独立的人脸特征提取方式. 由于人脸识别问题通常是一个小样本问题, 即其类内散布矩阵通常为奇异矩阵, 因而 FLD 无法直接用来提取鉴别特征, 必须同其他特征降维方法, 如 PCA 配合使用. 即在应用 FLD 进行特征提取之前, 首先用 PCA 对高维输入空间进行维数压缩, 使得压缩后的空间内不再出现奇异的类内散布矩阵. 事实上, 很多人脸特征提取方法, 如正交补空间法<sup>[14]</sup>、零空间法<sup>[11]</sup>以及组合空间法<sup>[12]</sup>等都是为了解决 Fisher 鉴别准则面临的类内散布矩阵的奇异性问题而逐渐发展起来的.

最大散度差鉴别准则<sup>[2]</sup>是一种新的线性鉴别准则, 它也是为了克服 Fisher 鉴别准则面临的奇异性问题而被提出来的. 最大散度差准则试图寻找一个最优投影方向, 使得不同类别的高维模式样本沿该方向投影后, 能被最大限度地分开. 与 Fisher 鉴别准则不同的是, 最大散度差准则采用广义散度差——类间散度减去  $C$  倍的类内散度 ( $C$  为模型参数, 通常为非负实数), 作为投影后数据的可分性度量, 而不再沿用广义 Rayleigh 商.

基于最大散度差鉴别准则的线性分类器——最大散度差分类器, 在人脸识别领域得到了良好运用. 实验结果表明, 其分类效果优于各种传统的人脸特征提取 (如 Eigenfaces 和 Fisherfaces) 加最近邻或最小距离分类器的识别方法, 甚至可以与具有很强泛化能力的支持向量机相媲美. 而且, 最大散度差分类器在人脸数据集上的分类性能并不明显依赖参数  $C$  的选择.

避免了奇异性问题、具有优良的分类效果、无须对参数进行烦琐的调试等优点, 使得最大散度差分类器成为一种新的富有成效的人脸识别方法. 但是, 最大散度差分类器本质上是一种两类分类器. 当应用于多类模式识别问题时, 必须首先对原问题进行分解, 将原来的一个多类分类问题转化为一系列两类分类问题. 如果采用“一对多”(one-vs-rest)方式, 一个  $l$  类分类问题对应到  $l$  个两类分类问题; 如果采用“一对一”(one-vs-one)或“有向树”(directed acyclic graph)方式, 一个  $l$  类分类问题则对应到  $l(l-1)/2$  个两类分类问题<sup>[14]</sup>. 研究表明, 最大散度差分类器在“一对多”分解方式下的识别率通常比较低, 因而不常使用. 如果采用“一对一”或“有向树”分解方式, 最大散度差分类器的识别率虽然能够得到保证, 但是随着类别个数  $l$  的不断增大, 最大散度差分类器的学习及分类效率将会

迅速降低.

为此,我们将适用于两类模式分类的最大散度差鉴别准则扩展到可用于特征提取的多类最大散度差鉴别准则. 本文首先简要介绍了最大散度差鉴别准则和最大散度差分类器,然后建立了多类最大散度差鉴别准则以及特征提取方法,给出了不同参数条件下的最大散度差特征脸图像,最后在 ORL、Yale 以及 FERET 人脸图像数据库上,与 Fisherfaces、Eigenfaces、正交补空间、零空间等人脸特征提取方法进行了比较. 测试结果表明,基于多类最大散度差鉴别准则的特征提取方法具有一定的优势.

## 2 最大散度差鉴别准则以及最大散度差分类器

设  $\omega_1$  和  $\omega_2$  是两个模式类, 模式  $\boldsymbol{x} \in R^d$  为  $d$  维实向量, 第  $i$  类训练样本的个数为  $N_i$ , 样本均值  $\boldsymbol{m}_i$ 、类间散布矩阵  $S_b$  和类内散布矩阵  $S_w$  分别定义为

$$\boldsymbol{m}_i = \frac{1}{N} \sum_{\boldsymbol{x} \in \omega_i} \boldsymbol{x}, \quad i = 1, 2 \quad (1)$$

$$S_b = (\boldsymbol{m}_1 - \boldsymbol{m}_2)(\boldsymbol{m}_1 - \boldsymbol{m}_2)^T \quad (2)$$

$$S_w = \sum_{i=1}^2 \sum_{\boldsymbol{x} \in \omega_i} (\boldsymbol{x} - \boldsymbol{m}_i)(\boldsymbol{x} - \boldsymbol{m}_i)^T \quad (3)$$

将模式样本沿某个方向  $\boldsymbol{w} \in R^d (\boldsymbol{w} \neq 0)$  进行投影, 投影后样本的类间散度  $\tilde{S}_b$  和类内散度  $\tilde{S}_w$  分别为

$$\tilde{S}_b = \frac{\boldsymbol{w}^T S_b \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{w}} \quad (4)$$

$$\tilde{S}_w = \frac{\boldsymbol{w}^T S_w \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{w}} \quad (5)$$

类间散度和类内散度是衡量数据可分性的两个常用指标. 类间散度愈大, 数据的可分性愈好; 类内散度愈小, 数据的可分性愈好. 通过线性加权, 我们可以将上述两个可分性指标综合成广义散度差

$$\frac{\boldsymbol{w}^T S_b \boldsymbol{w} - C \cdot \boldsymbol{w}^T S_w \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{w}} = \frac{\boldsymbol{w}^T (S_b - C \cdot S_w) \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{w}} \quad (6)$$

作为一个统一的可分性指标. 其中, 参数  $C$  为一非负实数.

最大散度差鉴别准则选取使得广义散度差达到最大的方向作为最优投影方向. 因此, 最大散度差鉴别准则对应着以下最优化模型:

$$\max_{\boldsymbol{w} \neq 0} \frac{\boldsymbol{w}^T (S_b - C \cdot S_w) \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{w}} \quad (7)$$

其中, 矩阵  $S_b - C \cdot S_w$  称为参数为  $C$  的广义散度差矩阵.

依据 [2], 我们有以下引理.

**引理 1.** 广义散度差矩阵  $S_b - C \cdot S_w$  最大特征值对应的特征向量即为最大散度差鉴别准则的最优投影方向.

记  $\boldsymbol{w}^*(C)$  为 (7) 式确定的最优投影方向, 高维模式样本  $\boldsymbol{x}$  沿该轴投影后, 得到一维特征  $\boldsymbol{w}^*(C)^T \boldsymbol{x}$ . 这样, 高维输入空间的模式分类问题即转化为一维特征空间的模式分类问题. 令  $b$  和  $b_1$  分别为所有训练样本和第一类训练样本沿  $\boldsymbol{w}^*(C)$  轴投影后的样本均值, 即

$$b = \frac{1}{N_1 + N_2} \sum_{\boldsymbol{x} \in \omega_1 \cup \omega_2} \boldsymbol{w}^*(C)^T \boldsymbol{x} \quad (8)$$

$$b_1 = \frac{1}{N_1} \sum_{\mathbf{x} \in \omega_1} \mathbf{w}^*(C)^T \mathbf{x} \quad (9)$$

则, 基于最大散度差鉴别准则的最大散度差分类器为:

$$f(\mathbf{x}) = \text{sign}(\mathbf{w}^*(C)^T \mathbf{x} - b) \cdot \text{sign}(b_1 - b) \quad (10)$$

其中,  $\text{sign}$  为符号函数.  $f(\mathbf{x}) = 1$  表示  $\mathbf{x}$  属于  $\omega_1$ ,  $f(\mathbf{x}) = -1$  表示  $\mathbf{x}$  属于  $\omega_2$ .

### 3 多类最大散度差鉴别准则与特征提取

设  $\omega_1, \omega_2, \dots, \omega_l$  是  $l$  个模式类, 模式  $\mathbf{x} \in R^d$  为  $d$  维实向量, 第  $i$  类训练样本的个数为  $N_i$ , 则第  $i$  类样本均值  $\mathbf{m}_i$ 、总体样本均值  $\mathbf{m}$ 、类间散布矩阵  $S_B$  和类内散布矩阵  $S_W$  分别定义为:

$$\mathbf{m}_i = \frac{1}{N} \sum_{\mathbf{x} \in \omega_i} \mathbf{x}, \quad i = 1, 2, \dots, l \quad (11)$$

$$\mathbf{m} = \frac{1}{N} \sum_{i=1}^l N_i \mathbf{m}_i, \quad N = \sum_{i=1}^l N_i \quad (12)$$

$$S_B = \sum_{i=1}^l N_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (13)$$

$$S_W = \sum_{i=1}^l \sum_{\mathbf{x} \in \omega_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T \quad (14)$$

此时, 广义散度差矩阵为  $S_B - C \cdot S_W$ .

我们的任务是试图确定  $k$  个最优鉴别向量  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k$ , 使得不同类别的高维模式样本沿这些向量投影后, 能被最大限度地分开. 为消除特征之间的线性相关性以及最优鉴别向量长度不一带来的影响, 通常要求它们为规范正交向量组, 即满足  $\mathbf{w}_i^T \mathbf{w}_j = \delta_{ij}, i, j = 1, 2, \dots, k$ . 记  $W = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k] \in R^{d \times k}$ , 模式样本  $\mathbf{x}$  沿这些轴投影后得到特征向量  $W^T \mathbf{x}$ . 所有训练样本的特征向量构成的类间散布矩阵  $\tilde{S}_B$  和类内散布矩阵  $\tilde{S}_W$ , 分别为  $W^T S_B W$  和  $W^T S_W W$ . 模式样本投影后的广义散度差矩阵为  $W^T (S_B - C \cdot S_W) W$ .

由于类间散布矩阵  $W^T S_B W$  的迹  $\text{tr}(W^T S_B W)$  反映出投影后不同类别平均模式样本之间存在的总的差异的大小, 而类内散布矩阵  $W^T S_W W$  的迹  $\text{tr}(W^T S_W W)$  则反映出投影后同一类别模式样本之间存在的总的差异的大小, 因此可以用广义散度差矩阵  $W^T (S_B - C \cdot S_W) W$  的迹  $\text{tr}[W^T (S_B - C \cdot S_W) W]$  作为投影后数据的可分性度量. 其值越大, 数据的可分性就越好.

于是, 我们有以下多类最大散度差鉴别准则: 选择使得  $\text{tr}[W^T (S_B - C \cdot S_W) W]$  达到最大值的投影方向  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k$  作为最优投影方向. 其中,  $W = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k], \mathbf{w}_i^T \mathbf{w}_j = \delta_{ij}, i, j = 1, 2, \dots, k$ .

多类最大散度差鉴别准则对应于以下最优化模型:

$$\max_{\mathbf{w}_i^T \mathbf{w}_j = \delta_{ij}, i, j = 1, 2, \dots, k} \text{tr}\{[\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k]^T (S_B - C \cdot S_W) [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k]\} \quad (15)$$

上述最优化模型可以改写为

$$\max_{\mathbf{w}_i^T \mathbf{w}_j = \delta_{ij}, i, j = 1, 2, \dots, k} \sum_{i=1}^k \mathbf{w}_i^T (S_B - C \cdot S_W) \mathbf{w}_i \quad (16)$$

依据 [13], 我们有以下引理.

**引理 2.** 设  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$  为广义散度差矩阵  $S_B - C \cdot S_W$  的前  $k$  个特征值,  $\varphi_1, \varphi_2, \dots, \varphi_k$  为对应的一组规范正交特征向量, 则

$$1) \max_{\mathbf{w}_i^T \mathbf{w}_j = \delta_{ij}, i, j = 1, 2, \dots, k} \sum_{i=1}^k W_i^T (S_B - C \cdot S_W) W_i = \lambda_1 + \lambda_2 + \dots + \lambda_k$$

$$2) \sum_{i=1}^k \varphi_i^T (S_B - C \cdot S_W) \varphi_i = \lambda_1 + \lambda_2 + \dots + \lambda_k$$

这意味着广义散度差矩阵  $S_B - C \cdot S_W$  的前  $k$  个特征向量构成的规范正交特征向量组  $\varphi_1, \varphi_2, \dots, \varphi_k$ , 即为多类最大散度差鉴别准则的一个最优解.

下面给出基于多类最大散度差鉴别准则的特征提取方法.

第一步, 根据给定的训练样本集计算类内散布矩阵  $S_W$  和类间散布矩阵  $S_B$ ;

第二步, 根据选定的参数  $C$ , 计算广义散度差矩阵  $S_B - C \cdot S_W$ ;

第三步, 根据选定的参数  $k$ , 确定出广义散度差矩阵前  $k$  个规范正交的特征向量  $\varphi_1, \varphi_2, \dots, \varphi_k$ ;

第四步, 将所有模式向量  $\mathbf{x}$  投影到各个投影轴  $\varphi_1, \varphi_2, \dots, \varphi_k$ , 得到特征向量  $\Phi^T \mathbf{x}$ . 其中,  $\Phi = [\varphi_1, \varphi_2, \dots, \varphi_k]$ .

显然, 这种特征提取方法并不局限于人脸识别领域, 同样也适用于其他模式分类如字符识别、文本分类等领域.

## 4 最大散度差特征脸图像

将广义散度差矩阵  $S_B - C \cdot S_W$  的特征向量还原为人脸图像, 我们可以得到类似于 Eigenfaces 的特征脸图像. 图 1 是当参数  $C$  的值分别为 100, 10, 1, -1 时, ORL 数据集上广义散度差矩阵  $S_B - C \cdot S_W$  前 5 个特征向量的图像.



图 1 当参数  $C$  的值分别为 100, 10, 1, -1 时, 广义散度差矩阵前 5 个特征向量的图像  
Fig. 1 Images corresponding to the first five eigenvectors of a generalized scatter difference matrix when parameter  $C$  equals 100, 10, 1, and -1, respectively

由于  $S_B - (-1) \cdot S_W = S_B + S_W = S_T$  为总散布矩阵, 意味着  $C = -1$  时的广义散度差特征脸实际上就是 Eigenfaces.

从图中可以看出, 随着参数  $C$  取值的不断增大, 特征脸的细节越来越丰富. 与 Eigenfaces 主要反映各类样本的共同特点不同, 广义散度差特征脸反映的则是各类样本的主要差异.

## 5 仿真实验

### 实验 1

数据集为 ORL 人脸图像数据库, 它由 40 人、每人 10 幅  $112 \times 92$  灰度图像所组成. 原始图像对应的输入空间维数高达 10,304 维, 使得广义散度差矩阵  $S_B - C \cdot S_W$  的特征向量的计算变得非常困难. 为减少计算量, 我们首先将每幅图像的分辨率由  $112 \times 92$  降低到  $56 \times 46$ , 然后在压缩后的 2,576 维输入空间上用多类最大散度差鉴别准则进行特征提取. 选取每个人的前 5 幅图像作为训练样本、后 5 幅图像作为测试样本, 训练样本个数和测试样本个数均为 200. 分别用 Eigenfaces<sup>[7]</sup>、Fisherfaces<sup>[8]</sup>、组合空间表示法<sup>[12]</sup> 和多类最大散度差进行特征提取, 并用最近邻分类器进行分类, 得识别错误数如表 1 所示.

从表中数据不难看出, 基于多类最大散度差鉴别准则的特征提取方法明显优于传统的 Eigenfaces 和 Fisherfaces, 略优于组合空间表示法. 而且, 参数  $C$  的变化对识别结果没有明显影响.

表 1 ORL 数据集上不同特征提取方法的识别错误数

Table 1 Recognition errors of various feature extraction methods on ORL database

投影轴数	Eigenfaces	Fisherfaces	组合空间 表示法	最大散度差			
				$C = 1000$	$C = 100$	$C = 10$	$C = 1$
24	14	28	12	11	8	11	9
29	15	31	11	10	9	10	8
34	14	28	10	9	8	9	9
39	14	23	8	7	7	8	9

### 实验 2

数据集为 Yale 人脸图像数据集, 它由 15 人、每人 11 幅在不同面部表情和光照条件下的灰度图像所组成, 图像分辨率为  $100 \times 80$ . 实验采用“留一法”. 即一共进行 165 次测试, 第  $i$  次测试的测试样本为数据集中的第  $i$  幅图像, 训练样本为除此之外的所有其他 164 幅图像. 实验结果为这 165 次测试的平均结果. 为降低内存和时间消耗, 先用主成分分析将 8,000 维的原始输入空间压缩到 163 维的 PCA 空间, 然后在此空间上进行特征提取, 最后仍然采用最近邻分类器进行分类. 实验一共考察了 Eigenfaces、Fisherfaces、正交补空间表示法<sup>[14]</sup>、零空间法表示法<sup>[11]</sup> 和基于多类最大散度差鉴别准则的特征提取方法. 除 Eigenfaces 采用所有 163 个 PCA 特征之外, 其它均在这 163 个 PCA 特征基础上再提取 14 个鉴别特征. 实验结果如表 2 所示.

从表中数据可以看出, 基于多类最大散度差鉴别准则的特征提取方法明显优于传统的 Eigenfaces 和 Fisherfaces, 与正交补空间表示法和零空间表示法相当. 而且, 参数  $C$  的变化对识别结果没有显著影响.

表 2 Yale 数据集上不同特征提取方法的识别率

Table 2 Recognition rates of various feature extraction methods on Yale database

特征提取方法	Eigenfaces	Fisherfaces	正交补空 间表示法	零空间 表示法	最大散度差		
					$C = 1000$	$C = 100$	$C = 10$
识别率	81.82%	72.73%	98.18%	98.18%	98.18%	98.18%	99.39%

### 实验 3

数据集采用 FERET 人脸图像数据库. 它是一个大型人脸库, 包含有 3737 幅人脸图像. 实验中, 我们选取其中的 200 人, 每人 7 幅图像. 由于包含的类别个数多, 同类人脸图像的光照条件、表情、姿态等变化大, 相对于 ORL 和 Yale 而言, FERET 很难识别. 为消除人脸位置、光照等因素的影响, 我们采用了分辨率为  $80 \times 80$  的标准化灰度图像, 并进行了灰度均衡化处理.

实验一共进行 7 次测试, 第  $i$  次测试的训练样本为每个人脸的第  $i, i+1, i+2$  幅图像<sup>2)</sup>, 测试样本为除此之外的所有其他 4 幅图像. 每次测试时的训练样本个数和测试样本个数分别为 600 和 800. 实验结果为这 7 次测试的平均结果. 同实验二一样, 先用主成分分析将 6,400 维的原始输入空间压缩到 599 维的 PCA 空间, 然后在此空间上进行特征提取, 最后仍然采用最近邻分类器进行分类. 实验一共考察了 Eigenfaces、Fisherfaces、正交补空间表示法、零空间表示法和基于多类最大散度差鉴别准则的特征提取方法. 除 Eigenfaces 采用所有 599 个 PCA 特征之外, 其它均在这 599 个 PCA 特征基础上再提取 199 个鉴别特征. 实验结果如表 3 所示.

表 3 FERET 数据集上不同特征提取方法的识别率

Table 3 Recognition rates of various feature extraction methods on FERET database

特征提取方法	Eigenfaces	Fisherfaces	正交补空 间表示法	零空间 表示法	最大散度差		
					$C = 100$	$C = 10$	$C = 1$
识别率	52.11%	25.18%	58.73%	52.82%	55.91%	61.95%	59.64%

从表中数据不难看出, 基于多类最大散度差鉴别准则的特征提取方法明显优于传统的 Eigenfaces 和 Fisherfaces, 优于正交补空间表示法和零空间表示法.

## 6 结束语

理论分析和实验检验表明, 就人脸识别而言, 基于多类最大散度差鉴别准则的特征提取方法, 相对于许多传统的特征提取方法具有一定的优势. 首先, 多类最大散度差鉴别准则继承了两类最大散度差鉴别准则的优点, 用广义散度差代替广义 Rayleigh 商, 从而避免了 Fisher 鉴别准则面临的类内散布矩阵的奇异性问题. 其次, 基于多类最大散度差鉴别准则的特征提取方法具有良好的特征表示能力, 在多个国际标准人脸库上的对比实验表明, 该方法明显优于传统的 Eigenfaces 和 Fisherfaces, 优于正交补空间、零空间等表示法或与之相当.

## References

- 1 Song F X, Yang J Y, Liu S H. Large margin linear projection and face recognition. *Pattern Recognition*, 2004, **37**(9): 1953~1955
- 2 Song F X, Cheng K, Yang J Y, Liu S H. Maximum scatter difference, large margin linear projection and support vector machines. *Acta Automatica Sinica*, 2004, **30**(6): 890~896
- 3 Song F X, Yang J Y, Liu S H. Pattern recognition based on the minimum norm minimum squared-error classifier. In: Proceedings of the Eighth International Conference on Control, Automation, Robotics and Vision (ICARCV 2004), Kuming, China: IEEE Press, 2004. 1114~1117
- 4 Kohonen T. Self-Organization and Associative Memory. Berlin: Springer, 1988
- 5 Guo G D, Li S Z, Chan K L. Support vector machines for face recognition. *Image and Vision Computing*, 2001, **19**(9,10): 631~638
- 6 Kanade T. Computer Recognition of Human Faces. Basel and Stuttgart: Birkhauser, 1977
- 7 Turk M, Pentland A. Human face recognition. *Journal of Cognitive Neuroscience*, 1991, **3**(1): 71~86
- 8 Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs fisherfaces: Recognition using class specific linear projections. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, **19**(7): 711~720

2) 当  $i+1, i+2$  大于 7 时, 它们分别用  $i+1-7, i+2-7$  代替

- 9 Bartlett M S, Movellan J R, Sejnowski T J. Face recognition by independent component analysis. *IEEE Transactions on Neural Networks*, 2002, **13**(6): 1450~1464
- 10 Yang J, Zhang David, Frangi A F, Yang J Y. Two-dimensional PCA: A new approach to appearance-based face representation and recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, **26**(1): 131~137
- 11 Chen L F, Liao H Y M, Ko M T, Lin J C, Yu G J. A new LDA-based face recognition system which can solve small size problem. *Pattern Recognition*, 2000, **33**(10): 1713~1726
- 12 Yang J, Yang J Y. Why can LDA be performed in PCA transformed space? *Pattern Recognition*, 2003, **36**(2): 563~566
- 13 Guo Y F, Li S J, Yang J Y, Shu T T, Wu L D. A generalized Foley-Sammon transform based on generalized fisher discriminant criterion and its application to face recognition. *Pattern Recognition Letters*, 2003, **24**(1-3): 147~158
- 14 Liu K, Cheng Y Q, Yang J Y. An efficient algorithm for Foley-Sammon optimal set of discriminant vectors by algebraic method. *International Journal of Pattern Recognition and Artificial Intelligence*, 1992, **6**(5): 817~829

**宋枫溪** 教授, 博士后. 研究方向为模式识别理论与应用.

(**SONG Feng-Xi** Professor in artillery academy and PDF in Shenzhen Graduate School at Harbin Institute of Technology. His research interests include pattern recognition theory and its application.)

**杨静宇** 教授, 博导. 研究方向为模式识别与智能系统.

(**YANG Jing-Yu** Professor at Nanjing University of Science and Technology. His research interests include pattern recognition and intelligent system.)

**刘树海** 教授, 博导. 研究方向为战场数据融合系统.

(**LIU Shu-Hai** Professor at Artillery Academy. His research interests include battle field data fusion system.)

**张大鹏** 教授, 博导. 研究方向为生物特征识别.

(**ZHANG David** Professor at Hong Kong Polytechnic University. His research interests include Biometric Recognition.)