

人脸识别中多目标最优不相关图像鉴别分析研究

陈秀宏^{1,2)} 杨静宇²⁾

¹⁾(江南大学信息工程学院, 无锡 214122) ²⁾(南京理工大学计算机系, 南京 200094)

摘要 考虑图像投影鉴别分析问题, 为提高特征抽取的速度和识别率, 利用图像矩阵直接构造图像散布矩阵, 在具有统计不相关的条件下将 Foley-Sammon 鉴别分析(FSLDA) 转化为两目标约束优化问题, 并给出了有效投影向量的概念; 根据多目标优化的最优性条件可将求取有效投影向量的问题归结为求广义特征方程的最大特征值对应的特征向量, 并据此进行特征抽取, 进而提出了两目标最优图像投影鉴别分析方法。与其他鉴别投影分析方法相比, 该方法具有以下特点: (1) 可直接由图像矩阵构建散布矩阵; (2) 有效投影向量具有统计不相关性; (3) 训练样本的类内散布矩阵不必为可逆的, 也不需要求某种形式矩阵的逆。在 ORL 标准人脸库和 NUST603 人脸库上的试验结果表明, 上述图像投影鉴别分析方法在识别性能上较以往的方法有一定的提高, 尤其是特征抽取的速度有明显的提高。

关键词 图像投影鉴别分析 图像有效投影向量集 图像特征抽取 多目标最优 最优性条件 人脸识别

中图分类号: TP391.41 **文献标识码**: A **文章编号**: 1006-8961(2007)12-2137-06

Multiobjective Optimal Uncorrelated Image Discriminant Analysis in Face Recognition

CHEN Xiu-hong^{1,2)}, YANG Jing-yu²⁾

¹⁾(School of Information Technology, Southern Yangtze University, Wuxi 214122)

²⁾(Department of Computer Science, Nanjing University of Science and Technology, Nanjing 200094)

Abstract This paper addressed the image discriminant analysis problem. By constructing the scattering matrices of the image matrices, Foley-Sammon discriminant analysis(FSLDA) are transformed into a bi-objective optimization problem with uncorrelated constraint for improving the speed of feature extraction and the recognition rate. The efficient projection vector is defined and the efficient projection vector can be obtained from deciding the eigenvector corresponding to the eigenvalue of maximum of a generalized eigen-equation. Compared with the other image projection analysis methods, the proposed method has the following properties: (1) the scattering matrices are directly based on image matrices; (2) the efficient projection vectors are statistically uncorrelated; (3) the within scattering matrix is not necessarily invertible and some matrix inversions are not performed. Finally, the proposed method is tested on ORL and NUST603 face databases. The experimental results indicate that the recognition performance of the proposed method is prior to the other methods, and its speed for feature extraction is faster than the above methods.

Keywords image projection discriminant analysis, image effective projection vector, image feature extraction, multiobjective optimization, optimality condition, face recognition

1 引言

线性鉴别分析是模式识别领域中公认的特征抽取的最为重要的工具之一, 目前仍然被广泛地应用

在人脸等图像识别领域^[1,2], 其研究最早可追溯到1936年 Fisher 所发表的论文^[3], 该文中是选择使得 Fisher 准则函数达到最优的向量作为最优投影方向, 因样本在该方向上的投影能达到最大类间散布度和最小散布度。Foley 和 Sammon 提出采用一组

基金项目: 国家自然科学基金项目(60472060); 江苏省高校自然科学基金和教育厅自然科学基金项目(03KJB110012, 01KJD110005)

收稿日期: 2005-10-12; 改回日期: 2006-09-26

第一作者简介: 陈秀宏(1964~), 男, 教授, 博士。主要研究领域包括优化理论与方法、模式识别、图像处理等。E-mail: xiuhongc@jiangnan.edu.cn

满足正交条件的最优投影向量作为特征抽取向量^[4]。Jin 等从统计不相关的角度考察了 Fisher 线性鉴别变换,进而导出了相关的算法^[5],并证实了算法的有效性。随后,杨健、杨静宇等进一步发展了具有统计不相关性的鉴别分析的理论,并给出了更为简明的算法^[6]。

以上方法在处理人脸识别等问题时,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,比如图像的分辨率为 112×92 ,那么所得的图像向量的维数可高达 10 304,这样,一方面在进行线性鉴别分析时会耗费大量的时间,另一方面对小样本问题,在实际工作中,由于难以找到或根本不可能找到足够多的样本来保证类内散布矩阵的可逆性,从而造成计算最优鉴别向量集的困难。针对这一问题,Liu 等人提出了利用图像矩阵直接构造图像散布矩阵的方法^[7];杨健、杨静宇从统计不相关性的角度改进了文献[7]的方法^[8],得到了一种具有统计不相关性的图像投影鉴别分析方法。

本文将 Fisher 鉴别分析问题转化为带约束条件的两目标优化问题,并给出了有效投影向量的概念及求取有效投影向量集的方法。该方法具有以下特点:①直接基于图像矩阵进行特征抽取,能方便地降低原始特征的维数;②在特征抽取过程中,无需求取有关矩阵的逆,从而极大地提高了特征抽取的速度;③保持了特征向量间的共轭正交性条件,从而消除了鉴别特征向量之间的相关性。在 ORL 标准人脸库和 NUST603 人脸库上的试验结果表明,本文所提出的方法在识别性能上较已有方法有了一定的提高,尤其是特征抽取的速度有了明显的提高。

2 图像投影鉴别分析方法

设模式类别有 c 个: $\omega_1, \omega_2, \dots, \omega_c, n_i$ 表示第 i 类训练样本数, $N = \sum_{i=1}^c n_i$ 为训练样本总数。第 i 类的第 j 个训练样本图像为 $m \times n$ 维的矩阵 $A_j^{(i)}$ ($j = 1, 2, \dots, n_i; i = 1, 2, \dots, c$)。第 i 类的训练样本的均值图像为 $\bar{A}^{(i)}$,所有训练样本的均值图像为 \bar{A} 。模式的类间散布矩阵和类内散布矩阵为

$$S_b = \sum_{i=1}^c P(\omega_i) (\bar{A}^{(i)} - \bar{A})^T (\bar{A}^{(i)} - \bar{A})$$

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

其中, $P(\omega_i)$ ($i = 1, 2, \dots, c$) 是第 i 类 w_i 的先验概率。易证明: S_b 和 S_w 均为 $n \times n$ 大小的非负定矩阵。

类似地,也可以定义图像的总散布矩阵为

$$S_t = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{n_i} (A_j^{(i)} - \bar{A})^T (A_j^{(i)} - \bar{A})$$

易证明 S_t 为非负定矩阵,且满足 $S_t = S_b + S_w$ 。

定义以下广义 Fisher 准则函数

$$J(\varphi) = \frac{\varphi^T S_b \varphi}{\varphi^T S_w \varphi} \quad (1)$$

将最大化该准则函数的单位向量称为最优投影向量,其直观的物理意义是将寻找这样的投影方向 φ ,使得图像矩阵在方向 φ 上投影后所得到的特征向量具有最大的类间散布量和最小的类内散布量。于是,图像投影鉴别分析的基本思想是:对于使准则函数达到最优的最优投影向量 φ ,若将大小为 $m \times n$ 的图像矩阵 A 通过线性变换 $Y = A\varphi$ 直接投影到 φ 上,则可得到一个 m 维的列向量,称之为图像 A 的投影特征向量。据此可进行鉴别分析。

由广义 Rayleigh 商的极值性质,可使得广义 Fisher 准则(式(1))极大化的最优投影方向即为以下与广义特征方程的最大特征值对应的特征向量

$$S_b \varphi = \lambda S_w \varphi \quad (2)$$

一般说来,在样本类别数较多的情况下,单一的最优投影轴是不够的,因此,Liu 等人提出采用以下方法寻找一组最优投影向量集 $\{\varphi_1, \varphi_2, \dots, \varphi_d\}$ 作为投影轴:第 1 个投影轴 φ_1 取为广义 Fisher 最优投影方向;一旦确定了前 i 个投影轴 $\varphi_1, \varphi_2, \dots, \varphi_i$,则第 $i+1$ 个投影轴 φ_{i+1} 就是以下最优化问题的最优解:

$$\min J(\varphi)$$

$$\text{s. t. } \varphi_j^T \varphi = 0; j = 1, 2, \dots, i; \varphi \in \mathbb{R}^n \quad (3)$$

并有以下结果:

定理 1 φ_{i+1} 为以下与广义特征方程的最大特征值对应的规一化的特征向量:

$$B_i S_b \varphi = \lambda S_w \varphi \quad (4)$$

其中, $B_i = I_n - D_i^T (D_i S_w^{-1} D_i^T)^{-1} D_i S_w^{-1}$, $D_i = (\varphi_1, \varphi_2, \dots, \varphi_i)^T$ 。

如以 S_t 正交条件代替标准正交条件(式(3)),即令 $\varphi_1, \varphi_2, \dots, \varphi_d$ 满足以下条件:

$$\varphi_i^T S_t \varphi_j = 0; i \neq j; i, j = 1, 2, \dots, d$$

那么将满足以上共轭正交条件,且使得广义 Fisher 准则达到最优的投影向量称之为统计不相关的最优

投影矢量^[5]。于是第 $i+1$ 个投影轴 φ_{i+1} 就是以下最优化问题的最优解:

$$\begin{aligned} \min \quad & J(\varphi) \\ \text{s. t.} \quad & \varphi_j^T S_i \varphi = 0, j = 1, 2, \dots, i \end{aligned} \quad (5)$$

并有以下结果:

定理 2 最优解 φ_{i+1} 为以下与广义特征方程的最大特征值对应的特征向量:

$$B_i S_b \varphi = \lambda S_w \varphi \quad (6)$$

其中, $B_i = I_n - S_i D_i^T (D_i S_i S_w^{-1} S_i D_i^T)^{-1} D_i S_i S_w^{-1}$, $D_i = (\varphi_1, \varphi_2, \dots, \varphi_i)^T$ 。

笔者注意到,在以上两种方法中,均要求类内散布矩阵是非奇异(可逆)的。

当最优投影向量组 $\{\varphi_1, \varphi_2, \dots, \varphi_d\}$ 确定之后,即可将已知的图像样本 A 投影到这些向量上,即令 $y_i = A\varphi_i, i = 1, 2, \dots, d, y_1, y_2, \dots, y_d$ 称为图像样本 A 在 $\varphi_1, \varphi_2, \dots, \varphi_d$ 上的投影特征向量,它们可合并为一个 $M = md$ 维的图像 A 的整体投影特征向量:

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_d \end{bmatrix} = \begin{bmatrix} A\varphi_1 \\ A\varphi_2 \\ \vdots \\ A\varphi_d \end{bmatrix} \quad (7)$$

该特征向量可用于以后的分类识别。

3 两目标统计不相关最优鉴别分析方法

极大化广义 Fisher 准则函数(式(1))就是在极大化类间散布度 $\varphi^T S_b \varphi$ 的同时,极小化类内散布度 $\varphi^T S_w \varphi$,它亦可表示为以下两目标优化问题(下面用(I)代表):

$$\begin{aligned} \max \quad & (\varphi^T S_b \varphi, -\varphi^T S_w \varphi) \\ \text{s. t.} \quad & \varphi^T \varphi = 1 \end{aligned}$$

其中,约束是使得鉴别向量取单位向量,即标准化。

根据多目标优化的必要条件^[9,10],若 $\hat{\varphi}$ 为两目标优化问题(I)的有效解,则存在实数 $\hat{\lambda}_1, \hat{\lambda}_2$ 及 $\hat{\mu}$,使得

$$\hat{\lambda}_1 S_b \hat{\varphi} - \hat{\lambda}_2 S_w \hat{\varphi} - \hat{\mu} \hat{\varphi} = 0 \quad (8)$$

$$\lambda_1 \geq 0, \lambda_2 \geq 0, \lambda_1 + \lambda_2 = 1$$

由式(8)得

$$(\hat{\lambda}_1 S_b - \hat{\lambda}_2 S_w) \hat{\varphi} = \hat{\mu} \hat{\varphi}, \hat{\mu} = \hat{\varphi}^T (\hat{\lambda}_1 S_b - \hat{\lambda}_2 S_w) \hat{\varphi}$$

又由多目标优化问题有效解的充分条件^[9]知,如果 $\hat{\varphi}$ 为单目标问题“ $\max_{\varphi^T \varphi = 1} \{\hat{\lambda}_1 \varphi^T S_b \varphi - \hat{\lambda}_2 \varphi^T S_w \varphi\}$ ”的最优解,且 $\hat{\mu}$ 为其最优值,那么 $\hat{\varphi}$ 也是问题(I)的

有效解。这样,如果 $\hat{\varphi}$ 为与以下特征方程的最优特征值 $\hat{\mu}$ 对应的特征向量

$$(\hat{\lambda}_1 S_b - \hat{\lambda}_2 S_w) \varphi = \mu \varphi \quad (9)$$

则 $\hat{\varphi}$ 也是问题(I)的有效解。于是可得以下结论。

定理 3 两目标优化问题(I)的有效解是与特征方程(式(9))的最大特征值对应的特征向量。

本文所介绍的图像投影鉴别分析法是按以下方法寻找一组投影矢量集 $\{\varphi_1, \varphi_2, \dots, \varphi_d\}$ 作为投影轴:第 1 个投影轴 φ_1 取为与特征方程(式(9))的最大特征值对应的特征向量;一旦确定了前 i 个投影轴 $\varphi_1, \varphi_2, \dots, \varphi_i$,那么第 $i+1$ 个投影轴 φ_{i+1} 就是以下两目标优化问题(以下用(II)代表)的有效解:

$$\max \quad (\varphi^T S_b \varphi, -\varphi^T S_w \varphi) \quad (10)$$

$$\text{s. t.} \quad \varphi_j^T S_i \varphi = 0, j = 1, 2, \dots, i$$

$$\varphi^T \varphi = 1 \quad (11)$$

其中,第 1 个约束是使所得的投影方向具有统计不相关性,第 2 个约束是用于对投影方向进行归一化处理,即标准化。由此得到的图像投影鉴别分析法称为两目标统计不相关最优鉴别分析方法(uncorrelated bi-objective optimization discriminant analysis, UBODA)。并有以下结论。

定理 4 UBODA 法中最优投影方向 φ_{i+1} 为与以下广义特征方程的最大特征值对应的特征向量:

$$(I_n - S_i D_i^T D_i) (\lambda_1 S_b - \lambda_2 S_w) \varphi = \lambda S_i \varphi \quad (12)$$

其中, $D_i = (\varphi_1, \varphi_2, \dots, \varphi_i)^T$, λ_1 与 λ_2 是可预先给定的两个满足 $\lambda_1 + \lambda_2 = 1$ 的非负实数。

证明 如果 φ_{i+1} 为 UBODA 法中最优投影方向,则它即为问题(II)的有效解,由多目标优化问题有效解的必要条件^[9,10]知,存在实数 $\lambda_1, \lambda_2, \mu_j, j = 1, 2, \dots, i$ 及 λ 使得

$$2\lambda_1 S_b \varphi_{i+1} - 2\lambda_2 S_w \varphi_{i+1} - \sum_{j=1}^i \mu_j S_i \varphi_j - 2\lambda S_i \varphi_{i+1} = 0 \quad (13)$$

$$\lambda_1 \geq 0, \lambda_2 \geq 0, \lambda_1 + \lambda_2 = 1 \quad (14)$$

式(13)的两边分别左乘 φ_{i+1} 和第 r 个向量 φ_r^T , 并利用式(10)和式(11)得

$$\lambda = \lambda_1 \varphi_{i+1}^T S_b \varphi_{i+1} - \lambda_2 \varphi_{i+1}^T S_w \varphi_{i+1},$$

$$2\lambda_1 \varphi_r^T S_b \varphi_{i+1} - 2\lambda_2 \varphi_r^T S_w \varphi_{i+1} = \sum_{j=1}^i \mu_j \varphi_r^T S_i \varphi_j \quad r = 1, 2, \dots, i$$

记 $\mu = (\mu_1, \mu_2, \dots, \mu_i)^T$, 那么由式(10)和式(11)有 $D_i^T D_i = I$, 并且

$$\mu = 2D_i^T(\lambda_1 S_b - \lambda_2 S_w)\varphi_{i+1}$$

把 μ 代入式(13)得

$$(\mathbf{I}_n - S_i D_i^T D_i)(\lambda_1 S_b - \lambda_2 S_w)\varphi_{i+1} = \lambda S_i \varphi_{i+1}$$

这表明 φ_{i+1} 为广义特征方程(式(12))的特征向量。

另一方面,如果对两个确定的非负实数 λ_1 与 $\lambda_2: \lambda_1 + \lambda_2 = 1$, $\hat{\varphi}$ 为以下优化问题的最优解

$$\begin{aligned} \max \quad & \lambda_1 \varphi^T S_b \varphi - \lambda_2 \varphi^T S_w \varphi \\ \text{s. t.} \quad & \text{式(10)和式(11)} \end{aligned}$$

且 $\hat{\lambda}$ 为其最优值,那么由多目标优化有效解的充分条件^[9]知, $\hat{\varphi}$ 也是两目标优化问题(II)的有效解。于是,如果 φ_{i+1} 为与广义特征方程(式(12))的最大特征值 $\hat{\lambda}$ 对应的特征向量,那么 φ_{i+1} 也是两目标优化问题(II)的有效解。证毕

这样,如果要求取下一个统计不相关投影方向,则只需求取两目标优化问题(II)的有效解,本文把两目标优化问题(II)的有效解称之为有效的统计不相关投影方向。

在广义特征方程(式(12))中,既不要求类内散布矩阵 S_w 为非奇异的,也不需要求取形如 $D_i S_w^{-1} D_i^T$ 或 $D_i S_i S_w^{-1} S_i D_i^T$ 矩阵的逆,这就为对小样本问题进行鉴别分析提供了一条新的途径,同时特征抽取的速度也可能会得到提高,下面实验的结果恰好也说明了这一点。

4 数值实验与分析

由前节定理 4 知,当利用 UBODA 法确定下一个有效的统计不相关投影方向时,则需要预先求得满足条件 $\lambda_1 + \lambda_2 = 1$ 的非负实数参数 λ_1 与 λ_2 , 而它们恰好是优化问题(II)的权,可通过优化问题(II)的目标函数来求得,具体方法请参见文献[10]。

4.1 实验 1

实验 1 是在 ORL 标准人脸库上进行,该人脸库由 40 人,每人 10 幅图像组成,其中有些图像是拍摄于不同时期的,不仅人的脸部表情、脸部细节及人脸姿态有着不同程度的变化,深度旋转和平面旋转可达 20° ,而且人脸的尺度也有多达 10% 的变化。每幅图像的分辨率是 112×92 。图 1 是 ORL 人脸库中某人的 5 幅测试图像。

本实验随机地从每个人的 10 幅图像中取 5 幅作为训练样本,其余 5 幅作为测试样本,这样训练样本与测试样本总数均为 200。试验时,先分别利用



图 1 ORL 人脸库中某人的 5 幅图像

Fig. 1 Five images of somebody in ORL face data

定理 1 和定理 2 计算出文献[7]方法的和统计不相关法的 10 个最优投影鉴别向量,再利用定理 4 计算出 UBODA 的 10 个有效不相关投影向量,最后再分别选取其中的 2 ~ 10 个向量作为投影轴,进行式(7)所示的特征抽取。于是,若取 k 个投影轴,则所得的整体投影特征向量的维数 $112 \times k$ 。在每个投影空间内,分别采用最近邻分类器和最小距离分类器进行分类,分类结果识别率见表 1。

表 1 ORL 人脸库上 3 种不同图像投影分析结果对照

Tab. 1 Comparison of three methods of image projection discriminant analysis on ORL face data

投影轴数	最小欧氏距离分类器			最近邻分类器		
	文献[7]方法	不相关法	UBODA法	文献[7]方法	不相关法	UBODA法
2	0.830	0.870	0.910	0.880	0.935	0.955
3	0.870	0.875	0.935	0.920	0.935	0.965
4	0.860	0.885	0.955	0.935	0.955	0.960
5	0.870	0.890	0.945	0.930	0.955	0.965
6	0.870	0.890	0.955	0.930	0.955	0.960
7	0.870	0.900	0.960	0.935	0.945	0.955
8	0.870	0.905	0.955	0.930	0.950	0.975
9	0.870	0.910	0.955	0.930	0.955	0.970
10	0.870	0.905	0.955	0.930	0.950	0.975

图 2 则给出了最小距离分类器下 UBODA 法与 2 维主成分分析(2DPCA^[11])法及分块 2DPCA 法^[12]在 ORL 库上的正确识别率的比较。

表 1 和图 2 表明,在最高正确识别率方面,UBODA 法要优于文献[7]提出的方法、统计不相关法、2DPCA 法及分块 2DPCA 法,这是因为在 UBODA 法中不必求矩阵的逆,从而充分保留了每个图像的原始信息,同时各有效不相关投影方向之间具有统计不相关性;另外,与 2DPCA 法及分块 2DPCA 法不同的是,UBODA 法在极大化类间散布度的同时,由于极小化了类内散布度,从而可进一步提高识别的效果。

此外,为说明 UBODA 法的鲁棒性,把最近邻分




图 2 3 种方法在 ORL 人脸库上正确识别率比较

Fig.2 Comparison of three methods of image projection discriminant analysis on ORL face data

类器下的最好识别结果、特征抽取和识别处理所花费的时间列于表 2。

表 2 3 种方法在最近邻分类器下的最好识别结果、特征抽取和识别的时间对照表

Tab.2 Comparison of three methods with the nearest classifier by the best recognition rate, the time of feature extract and recognition

鉴别方法	文献[7]方法	不相关法	UBODA 法
特征维数	112 × 7	112 × 6	112 × 8
识别率 (%)	93.5	95.5	97.5
特征抽取时间 (s)	22.34	20.45	2.61
识别时间 (s)	18.65	17.61	11.24
总时间 (s)	40.99	38.06	13.85

由表 2 可见,UBODA 法的特征抽取速度要明显快于其他两种方法,这是因为 UBODA 法求有效不相关投影向量时,不要求矩阵的逆,而文献[7]的图像投影分析方法和不相关图像投影分析方法均要求类间散布矩阵 S_w 可逆,且在求下一最优投影向量时需要求 $D_i S_w^{-1} D_i^T$ 或 $D_i S_i S_w^{-1} S_i D_i^T$ 的逆,这需要花费较多的时间。

4.2 实验 2

实验 2 是在一个规模较大的 NUST603 人脸数据库上进行,其中包含 96 人,每人 10 幅图像,部分原始图像见图 3。

由于此人脸库中图像背景较为复杂,且光照条



图 3 NUST603 人脸库上的部分原始图像

Fig.3 Some original images on NUST603 face data

件变化较大,图像中人的脸部表情和姿态也有着一定程度的变化,每幅图像的分辨率均为 128×128 ,所以为了便于识别,可首先利用文献[13]提供的算法将图像中的脸像切割出来,并规一化为 32×32 大小的标准图像(见图 4)。



图 4 NUST603 人脸库上的部分 32×32 的标准图像

Fig.4 Some 32×32 standard images on NUST603 face data

本实验的目的是为了检验 UBODA 法对光照的敏感程度,故在图像规一化的过程中,对图像的灰度不做任何处理。实验是随机取每人的 5 幅图像作为训练样本,其余 5 幅作为测试样本,这样训练样本和测试样本总数均为 480。实验时,先分别计算出文献[7]方法、统计不相关法和 UBODA 法的 10 个最优投影鉴别向量;然后依次选取其中的 2 ~ 10 个向量作为投影轴进行如式(7)所示的特征抽取。由于人脸灰度图像是 32×32 大小的矩阵,因此若取 k 个投影轴,则所得的整体投影特征向量的维数是 $32 \times k$;最后,在每个投影空间内,分别采用最近邻分类器和最小欧氏距离分类器进行分类,识别率见表 3。

表 3 NUST603 人脸库上 3 种图像投影分析结果对照表

Tab.3 Comparison of three methods of image projection discriminant analysis on NUST603 face data

投影轴数	最小欧氏距离分类器			最近邻分类器		
	文献[7]方法	不相关法	UBODA 法	文献[7]方法	不相关法	UBODA 法
2	0.798	0.890	0.881	0.877	0.921	0.931
3	0.819	0.908	0.898	0.887	0.956	0.950
4	0.821	0.921	0.919	0.900	0.954	0.954
5	0.827	0.925	0.931	0.908	0.960	0.963
6	0.833	0.925	0.940	0.910	0.960	0.967
7	0.844	0.942	0.940	0.919	0.965	0.971
8	0.856	0.944	0.944	0.921	0.965	0.978
9	0.863	0.944	0.944	0.921	0.965	0.979
10	0.863	0.944	0.950	0.915	0.960	0.981

为进一步说明 UBODA 法的有效性,在 NUST603 人脸库上,采用最小距离分类器将 UBODA 法的识别率与 2DPCA 法和分块 2DPCA 法的识别率进行了比较,结果如图 5 所示。

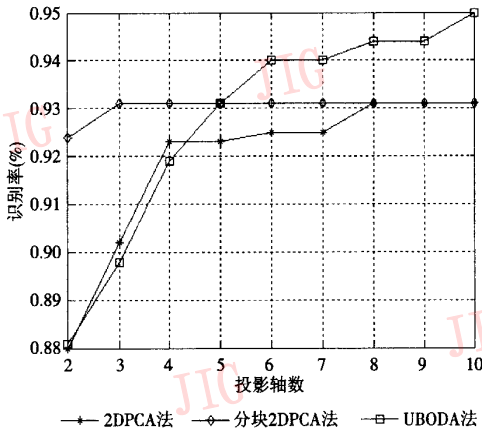


图 5 3 种方法在 NUST603 人脸库上正确识别率比较
Fig.5 Comparison of three methods of image projection discriminant analysis on NUST603 face data

表 3 和图 5 再次表明,UBODA 法要优于文献[7]提出的方法和统计不相关的图像投影鉴别分析方法,也优于 2DPCA 法和分块 2DPCA 法。另外,本试验也说明了本文方法对于图像光照的变化具有较好的鲁棒性,同时也发现 UBODA 法的特征抽取速度明显地要快于其他方法。

5 结 论

本文从算法本身出发,设计了直接针对小样本问题的算法,它是将求解使广义 Fisher 准则函数达到最优,且满足 S_1 正交条件的最优投影向量问题转化为求解带标准化和正交化约束条件的两目标最优化问题,并得到了最优投影向量所满足的广义特征方程(式(12))。该方法除了具有统计不相关性的图像投影鉴别分析方法的特点外,最主要的特点是在求有效投影向量,即求特征方程(式(12))的与最大特征值对应的特征向量时,不需考虑类内散布矩阵或总体散布矩阵是否为可逆的。实验结果表明,本文方法在识别性能上优于目前已有的一些鉴别分析方法,且特征抽取的速度也有显著的提高。

参考文献 (References)

- 1 Fukunaga K. Introduction to Statistical Pattern Recognition [M]. New York: Academic Press, 1990.
- 2 Bian Zhao-qi, Zhang Xue-gong. Pattern Recognition (2nd edition) [M]. Beijing: Tsinghua University Press, 1999. [边肇祺, 张学工. 模式识别(第二版)[M]. 北京: 清华大学出版社, 1999.]
- 3 Fisher R A. The use of multiple measurements in taxonomic problem [J]. Annals of Eugenics, 1936, 7(2): 179 ~ 188.
- 4 Foley D H, Sammon J W. An optimal set of discriminant vectors [J]. IEEE Transactions on Computer, 1975, 24(3): 281 ~ 289.
- 5 Jin Z, Yang J Y, Hu Z S, et al. Face recognition based on uncorrelated discriminant transformation [J]. Pattern Recognition, 2001, 34(7): 1405 ~ 1416.
- 6 Yang Jian, Yang Jing-yu, Jin Zong. An optimal discriminant feature extraction method and its application in image recognition [J]. Journal of Computer Research and Development, 2001, 38(11): 1331 ~ 1336. [杨健, 杨静宇, 金忠. 最优鉴别特征的抽取及图像识别[J]. 计算机研究与发展, 2001, 38(11): 1331 ~ 1336.]
- 7 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.
- 8 Yang Jian, Yang Jing-yu. Uncorrelated image projection discriminant analysis and face recognition [J]. Journal of Computer Research and Development, 2003, 40(3): 447 ~ 452. [杨健, 杨静宇. 具有统计不相关的图像投影鉴别分析及人脸识别[J]. 计算机研究与发展, 2003, 40(3): 447 ~ 452.]
- 9 Geoffrion A M. Proper efficiency and the theory of vector maximization [J]. Journal of Mathematical Analysis and Applications, 1968, 22: 618 ~ 630.
- 10 Hu Yu-da. Applied Multiobjective Optimization [M]. Shanghai: Shanghai Science & Technology Press, 1990. [胡毓达. 实用多目标最优化[M]. 上海: 上海科学技术出版社, 1990.]
- 11 Yang J, Zhang D, Yang J Y. Two-dimensional PCA: A new approach to appearance-based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131 ~ 137.
- 12 Chen Fu-bin, Chen Xiu-hong, Gao Xiu-mei, et al. Generalization of 2DPCA and its application in face recognition [J]. Computer Applications, 2005, 25(8): 1767 ~ 1770. [陈伏兵, 陈秀宏, 高秀梅等. 二维主成分分析方法的推广及其在人脸识别中的应用[J]. 计算机应用, 2005, 25(8): 1767 ~ 1770.]
- 13 Jin Zong. Research on Feature Extraction of Face Images and Feature Dimensionality [D]. Nanjing University of Science and Technology, Nanjing, 1999. [金忠. 人脸图像特征抽取与维数研究[D]. 南京理工大学, 南京, 1999.]