

# 基于奇异值分解和判别式 KL 投影的人脸识别\*

周德龙<sup>1+</sup>, 高文<sup>1,2,3</sup>, 赵德斌<sup>1,3</sup>

<sup>1</sup>(中国科学院 研究生院,北京 100039)

<sup>2</sup>(中国科学院 计算技术研究所,北京 100080)

<sup>3</sup>(哈尔滨工业大学 计算机科学与工程系,黑龙江 哈尔滨 150001)

## Face Recognition Based on Singular Value Decomposition and Discriminant KL Projection

ZHOU De-Long<sup>1+</sup>, GAO Wen<sup>1,2,3</sup>, ZHAO De-Bin<sup>1,3</sup>

<sup>1</sup>(Graduate School, The Chinese Academy of Sciences, Beijing 100039, China)

<sup>2</sup>(Institute of Computing Technology, The Chinese Academy of Sciences, Beijing 100080, China)

<sup>3</sup>(Department of Computer Science and Engineering, Harbin Institute of Technology, Harbin 150001, China)

+ Corresponding author: Phn: 86-10-82649005, E-mail: dlzhou@jdl.ac.cn

<http://www.jdl.ac.cn>

Received 2001-08-08; Accepted 2001-12-27

**Zhou DL, Gao W, Zhao DB. Face recognition based on singular value decomposition and Discriminant KL projection. *Journal of Software*, 2003,14(4):783~789.**

**Abstract:** The face recognition is an active subject in the fields of computer vision and pattern recognition, which has a wide range of potential applications. In this paper, a method for color face recognition is presented, this algorithm extracts the final features by utilizing the techniques of the simulative K-L transform, the singular value decomposition, the principal component analysis and the Fisher linear discriminant analysis. Classifier in this algorithm can be simplified to make it more compact and effective, and higher correct recognition rate can be gained using less number of feature vectors. The effectiveness of the approach is experimentally demonstrated.

**Key words:** face recognition; feature extraction; K-L transform; singular value feature vector; principal component analysis; Fisher linear discriminant analysis

**摘要:** 人脸识别是计算机视觉和模式识别领域的一个活跃课题,有着十分广泛的应用前景.提出了一种新的彩色人脸识别方法.该算法采用模拟 K-L 变换、奇异值分解、主分量分析和 Fisher 线性判别分析技术来提取最终特征,可以使分类器的设计更加简洁、有效,使用较少的特征向量数目就能取得较高的识别率.仿真结果表明了该方法的有效性.

**关键词:** 人脸识别;特征提取;K-L 变换;奇异值特征向量;主分量分析;Fisher 线性判别分析

中图法分类号: TP391 文献标识码: A

\* Supported by the National High-Tech Research and Development Plan of China under Grant No.2001AA114190 (国家高技术研究发展计划(863))

第一作者简介: 周德龙(1966—),男,浙江义乌人,博士,主要研究领域为图像处理,模式识别,人体生物特征识别.

人脸的自动识别是生物测定学研究的内容之一,是模式识别领域中的一个前沿课题.该课题的研究已有 30 多年的历史.目前,人脸的自动识别正越来越成为当前模式识别和人工智能领域的一个研究热点<sup>[1,2]</sup>.

真实的人脸图像是彩色的,这些色彩提供了比灰度人脸图像更为丰富的信息.目前,随着计算机技术的迅猛发展,彩色图像的处理已成为人们研究的热门课题.然而,由于灰度图像具有易于处理的特点,且大多数经典的图像处理方法都基于灰度图像,因此,如果将一幅彩色图像经过某种变换转换成灰度图像,使该灰度图像中包含原彩色图像中的绝大多数特征信息,那么,后续处理就可以采用经典的图像处理方法,大大减少了计算量.为了得到彩色人脸图像的主分量特征灰度图像,可以采用 Ohta<sup>[3]</sup>等人提出的最优基来模拟 K-L 变换方法,从而得到新的包含了彩色图像的绝大多数特征信息的主分量特征图像.

奇异值分解(singular value decomposition,简称 SVD)是一种有效的代数特征提取方法.由于奇异值特征在描述图像时是稳定的,且具有转置不变性、旋转不变性、位移不变性、镜像变换不变性等重要性质,因此奇异值特征可以作为图像的一种有效的代数特征描述<sup>[4-8]</sup>.奇异值分解技术已经在图像数据压缩、信号处理和模式分析中得到了广泛应用.

基于主成分分析(principal component analysis,简称 PCA)的人脸识别方法也称为特征脸方法(Eigenface)<sup>[9-11]</sup>.该方法将人脸图像按行(列)展开所形成的一个高维向量看作是一种随机向量,因此可以采用 K-L 变换获得其正交 K-L 基底.对应于其中较大特征值的基底具有与人脸相似的形状,故称其为特征脸.利用相对较小的 Eigenface 集描述人脸,这样每幅人脸图像就对应于一个维数较低的权向量,因此,人脸识别可以在降维后的空间上进行.然而,该方法的缺点是,得到的特征在一般情况下是最佳描述特征(the most expressive features,简称 MEFs),而不是最佳分类特征(the most discriminating features,简称 MDFs)<sup>[12]</sup>.

Fisher 线性判别方法(Fisher linear discriminant analysis,简称 FLD)使投影后的模式样本的类间散布矩阵最大而类内散布矩阵最小,也就是说,投影后保证模式样本在新的空间中有最大的类间距离和最小的类内距离,即模式在该空间中有最佳的可分离性.Fisher 线性判别分析提取的特征向量集强调的是不同人脸的差异而不是照明条件、人脸表情和方向的变化.因而,采用 FLD 方法对光照条件、人脸姿态等的变化不太敏感,从而有助于提高识别效果<sup>[13,14]</sup>.然而,由于在正常情况下人脸识别问题总是一个小样本问题,故其类内散布矩阵总为奇异阵而使此方法的求解变得很困难.

基于上面的分析,为了确保选择得到的最终特征是最佳鉴别特征,同时保证类内散布矩阵非奇异,在本文中我们提出了一种称为基于奇异值特征向量的 DKL(discriminant Karhunen-Loeve)彩色人脸识别方法.该方法首先采用 Ohta 提出的模拟 K-L 变换,将一幅彩色人脸图像转换成一幅彩色主分量特征的人脸灰度图像,然后使用矩阵的奇异值分解来获得奇异值特征向量,根据 PCA 投影来获得最佳描述特征,再利用 Fisher 线性判别分析投影来进一步降低特征空间的维数以获得最佳分类特征,最后由最近邻分类器识别人脸.

## 1 人脸图像的奇异值特征向量

任何一个实对称方阵都可以经过正交变换转化为对角阵,对于任意实矩阵  $A_{m \times n}$ ,则可以利用奇异值分解将其转化为对角阵.

引理(SVD)<sup>[15]</sup>. 令  $A_{m \times n}$  是实矩阵(不失一般性,设  $m \geq n$ ),且  $\text{rank}(A)=k$ ,则存在两个正交矩阵  $U_{m \times m}$  和  $V_{n \times n}$  及对角阵  $D_{m \times n}$  使下式成立:

$$A = UDV^T. \quad (1)$$

其中:

$$D_{m \times n} = \begin{pmatrix} \Sigma_{k \times k} & O \\ O & O \end{pmatrix}, \quad \Sigma_{k \times k} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k),$$

$$U_{m \times m} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_k, \mathbf{u}_{k+1}, \dots, \mathbf{u}_m), \quad V_{n \times n} = (\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_k, \mathbf{v}_{k+1}, \dots, \mathbf{v}_n),$$

式中  $T$  表示转置,  $\sigma_i = \sqrt{\lambda_i}$  ( $i=1, 2, \dots, k, \dots, n$ ) 称为矩阵  $A$  的奇异值,  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k > 0$  是  $AA^T$  并且也是  $A^T A$  的非零特征值的全体,而  $\lambda_{k+1} = \lambda_{k+2} = \dots = \lambda_n = 0$  为  $A^T A$  的  $n-k$  个零特征值.  $\mathbf{u}_i, \mathbf{v}_i$  ( $i=1, 2, \dots, k$ ) 分别是  $AA^T$  和  $A^T A$  对应于

非零特征值  $\lambda_i$  的特征向量.  $\mathbf{u}_i (i=k+1, \dots, m)$  是为了表达上的方便而引入的  $(m-k)$  个向量, 可以设想它是  $AA^T$  对应于  $\lambda_i = 0$  的特征向量. 同理,  $\mathbf{v}_i (i=k+1, \dots, n)$  为  $A^T A$  对应于  $\lambda_i = 0$  的特征向量. 将式(1)写成乘积的形式:

$$A = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^T. \quad (2)$$

如果矩阵  $A$  代表一幅人脸图像, 式(2)就是对该人脸图像进行了正交分解, 将矩阵  $\Sigma$  中主对角线上的奇异值元素  $\sigma_i$  连同  $D_{m \times n}$  中剩余的  $(n-k)$  个 0 构成一个  $n$  维列向量:

$$\mathbf{x}_{n \times 1} = D_{n \times n} \mathbf{e} = (\sigma_1, \dots, \sigma_k, 0, \dots, 0)^T. \quad (3)$$

其中,  $D_{n \times n}$  为  $D$  中的第 1 个  $n$  阶子式, 列向量  $\mathbf{e} = (1, 1, \dots, 1)^T_{n \times 1}$ , 称  $\mathbf{x}_{n \times 1}$  为  $A$  的奇异值特征向量. 对于任何实矩阵  $A$ , 在  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$  的限制下, 奇异值对角矩阵  $\Sigma$  是惟一的, 因此, 原人脸图像  $A$  对应于惟一的奇异值特征向量.

## 2 基于奇异值特征向量的 DKL 人脸识别方法

一幅彩色人脸图像经过模拟 K-L 变换之后可以得到新的互不相关的彩色特征. 由于第 1 个主分量中包含了原彩色图像的绝大多数特征信息, 因此我们仅考虑由第一主分量构成的图像, 并将其看作对应的人脸灰度图像. 人脸图像的奇异值向量特征由该图像矩阵根据奇异值分解得到, 矩阵的奇异值分解可以有效地降低特征空间维数, 然而, 所获得的奇异值向量特征依然有很高的维数, 如由一幅大小为  $210 \times 180$  的人脸图像得到的奇异值特征向量仍然高达 180 维, 因此, 有必要进一步降低特征空间的维数. 我们知道, 通过主分量分析能够获得互不相关的特征, 这些特征能对应地保留原模式中方差最大的特征成分, 因此, 我们在提取的奇异值特征向量空间的基础上, 再采用主分量分析技术(或 K-L 变换)来进一步降低特征空间的维数. 但 PCA 方法获得的特征是最佳描述特征而非最佳分类特征, 直接采用这些特征进行识别的效果并不好. 另一方面, 多类 Fisher 线性判别分析为我们提供了降低维数的一个合理途径和最佳的分类特征, 因此我们再采用 FLD 投影以获得最佳的分类特征, 然后在此子空间上进行识别. 该彩色人脸识别系统的框图结构如图 1 所示.

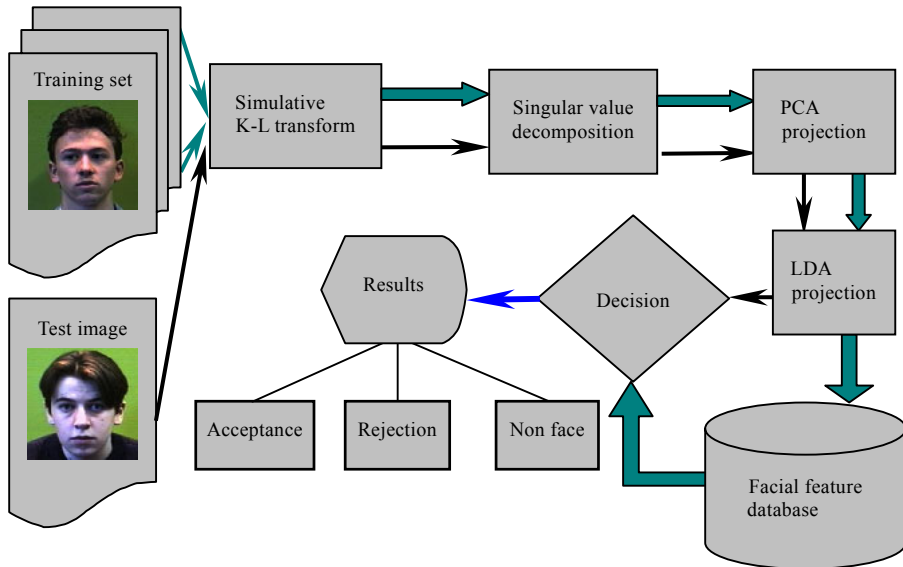


Fig.1 Architecture of the face recognition system

图 1 人脸识别系统结构

当人脸的样本数小于人脸样本向量的维数时, 类内散布矩阵是奇异的, 这时, 线性判别分析过程失效. 在本文中, 由于先要进行主分量分析投影, 然后再在 K-L 变换投影后的子空间中进行一次线性判别分析投影, 因此我们必须确保在 PCA 投影后的子空间中的类内散布矩阵是非奇异的. 这可以通过设置 PCA 投影后子空间的维数来达到.

设训练集的彩色人脸图像的大小均为  $m \times n$  (不失一般性,令  $m > n$ ),共有  $c$  类  $N$  幅彩色人脸图像  $\Gamma_i, i=1, 2, \dots, N$ , 由模拟 K-L 变换得到的人脸主分量特征图像为  $I_i, i=1, 2, \dots, N$ . 对人脸主分量特征图像矩阵  $I_i$  进行奇异值分解后得到的  $n$  维奇异值特征列向量为  $\mathbf{x}_i = (\sigma_{i1}, \dots, \sigma_{ir}, 0, \dots, 0)^T, i=1, 2, \dots, N$ , 其中  $r = \text{rank}(I_i)$ . 得到  $N$  个训练集的奇异值特征向量  $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ , 然后再投影到  $k$  维的最佳描述特征空间. 子空间维数  $k$  的选择应满足的条件是  $k \leq N-1$ , 因为在 K-L 变换投影中最多有  $N-1$  个非零特征值, 因此  $k > N-1$  是不可能的. 为了使该子空间中的类内散布矩阵  $S'_w$  非奇异, 进一步地对最佳描述特征空间的维数进行约束, 使其不大于对应于训练集样本的奇异值特征空间的类内散布矩阵  $S_w$  的秩. 另一方面, 应保证子空间维数  $k$  不小于类别数  $c$ , 以使该子空间中的样本尽量保持原模式空间分布结构. 因此, 最佳描述特征子空间维数  $k$  应满足如下条件:  $c \leq k \leq \min(\text{rank}(S_w), N-1)$ , 这时, 最佳描述特征子空间中训练样本的类内散布矩阵  $S'_w$  是非奇异的.

另外, 由于  $S_w^{-1} S_b$  最多只有  $c-1$  个非零特征值, 因此选择  $l \leq c-1$  作为最佳鉴别特征空间的维数. 这样, 最佳描述、最佳鉴别特征空间的维数选择必须满足如下条件:

$$l+1 \leq c \leq k \leq \min(\text{rank}(S_w), N-1). \quad (4)$$

这样, 通过主分量分析方法, 将  $n$  维奇异值特征列向量模式空间的维数降低到最佳描述特征空间的  $k$  维, 然后, 根据标准线性判别分析, 将维数降低到  $l$ . 这两次投影被称为 DKL 投影, 该 DKL 投影矩阵为

$$\mathbf{W}_{opt} = \mathbf{W}_{pca} \mathbf{W}_{fld}. \quad (5)$$

其中

$$\mathbf{W}_{pca} = \arg \max_{\mathbf{W}} |\mathbf{W}^T \mathbf{C} \mathbf{W}|, \quad (6)$$

$$\mathbf{W}_{fld} = \arg \max_{\mathbf{W}} \frac{|\mathbf{W}^T \mathbf{W}_{pca}^T S_b \mathbf{W}_{pca} \mathbf{W}|}{|\mathbf{W}^T \mathbf{W}_{pca}^T S_w \mathbf{W}_{pca} \mathbf{W}|}, \quad (7)$$

其中  $\mathbf{C}$  为训练集中提取的与人脸图像相对应的奇异值特征向量的协方差矩阵. DKL 投影的最佳鉴别特征为  $\mathbf{z} = \mathbf{W}_{fld}^T \mathbf{W}_{pca}^T \mathbf{x}$ , 其中  $\mathbf{W}_{pca}$  为从奇异值特征空间到最佳描述特征空间的投影矩阵,  $\mathbf{W}_{fld}$  为从最佳描述特征空间到最佳鉴别特征空间的投影矩阵.

$\mathbf{W}_{opt}$  的列向量是正交向量, 它表示的是人脸图像的奇异值特征向量经过 DKL 投影后的特征空间的坐标向量, 与特征脸不同, 该向量并不直接对应于相应模式的人脸.

在此, 我们将基于奇异值特征向量的 DKL 彩色人脸识别算法总结如下:

#### (一) 训练过程

(1) 给定一个彩色人脸图像的训练集  $\Gamma_i, i=1, 2, \dots, N$ , 采用 Ohta 最优基来模拟 K-L 变换, 从而将彩色人脸图像训练集中的每一幅彩色人脸图像转换成第一主分量对应的人脸灰度图像  $I_i, i=1, 2, \dots, N$ . 由这些灰度人脸图像构成相应的灰度人脸图像训练集.

(2) 根据奇异值分解定理计算相应灰度人脸图像训练集  $I_i, i=1, 2, \dots, N$  对应的奇异值特征向量  $\mathbf{x}_1^{sv}, \dots, \mathbf{x}_i^{sv}, \dots, \mathbf{x}_N^{sv}$ , 即  $\mathbf{x}_i^{sv} = (\sigma_1^i, \dots, \sigma_r^i, 0, \dots, 0)^T$ , 其中  $i=1, 2, \dots, N$ .

(3) 对奇异值特征向量空间进行坐标轴平移, 即以训练集的奇异值特征向量  $\mathbf{x}_1^{sv}, \dots, \mathbf{x}_i^{sv}, \dots, \mathbf{x}_N^{sv}$  的均值向量  $\mathbf{m}^{sv} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i^{sv}$  作为新坐标轴原点. 坐标轴平移后训练集的奇异值特征向量为  $\mathbf{x}_i = \mathbf{x}_i^{sv} - \mathbf{m}^{sv}$ ,  $i=1, 2, \dots, N$ .

(4) 计算由训练集奇异值特征向量  $\mathbf{x}_1, \dots, \mathbf{x}_i, \dots, \mathbf{x}_N$  构成的协方差矩阵中  $k$  个最大特征值对应的特征向量  $\mathbf{w}_1^{pca}, \dots, \mathbf{w}_i^{pca}, \dots, \mathbf{w}_k^{pca}$ . 这  $k$  个特征向量构成 PCA 投影矩阵  $\mathbf{W}_{pca} = [\mathbf{w}_1^{pca}, \dots, \mathbf{w}_i^{pca}, \dots, \mathbf{w}_k^{pca}]$ .

(5) 利用 PCA 投影矩阵  $\mathbf{W}_{pca}$  将奇异值特征向量空间转换为降维的  $k$  维 MEF 空间, 并获得最佳描述特征 MEFs. 即  $\mathbf{y}_i = (y_1^i, \dots, y_k^i)^T = \mathbf{W}_{pca}^T \mathbf{x}_i$ , 其中  $i=1, 2, \dots, N$ .

(6) 计算由训练集最佳描述特征  $\mathbf{y}_1, \dots, \mathbf{y}_i, \dots, \mathbf{y}_N$  构成的类内散布矩阵和类间散布矩阵  $S_w$  和  $S_b$ , 然后计算对应矩阵  $S_w^{-1} S_b$  的  $l$  个最大特征值对应的特征向量  $\mathbf{w}_1^{fld}, \dots, \mathbf{w}_i^{fld}, \dots, \mathbf{w}_l^{fld}$ . 由这  $l$  个最大特征值对应的特征向量构成

FLD 投影矩阵  $\mathbf{W}_{fld} = [\mathbf{w}_1^{fld}, \dots, \mathbf{w}_i^{fld}, \dots, \mathbf{w}_l^{fld}]$ .

(7) 利用 FLD 投影矩阵  $\mathbf{W}_{fld}$  将 MEF 空间转换为降维的  $l$  维 MDF 空间,获得对应的最佳分类特征 MDFs. 即  $\mathbf{z}_i = (z_1^i, \dots, z_l^i)^T = \mathbf{W}_{fld}^T \mathbf{y}_i$ , 其中  $i = 1, 2, \dots, N$ .

(8) 根据这些对应人脸图像训练集的最佳分类特征向量(MDFs)  $\mathbf{z}_1, \dots, \mathbf{z}_i, \dots, \mathbf{z}_N$  组成  $c$  类人脸识别数据库.需存储的人脸训练样本的特征向量数目需根据具体的分类方法来确定.若采用最近邻法,则需存储所有训练样本的特征向量.为表达方便起见,在此我们不妨假设由这  $N$  个最佳分类特征向量  $\mathbf{z}_1, \dots, \mathbf{z}_i, \dots, \mathbf{z}_N$  组成的  $c$  类人脸识别数据库中的标准样本向量为  $\mathbf{z}^{(1)}, \dots, \mathbf{z}^{(i)}, \dots, \mathbf{z}^{(c)}$ .

(9) 计算两个人脸类之间的最大允许距离:  $T_1 = \frac{1}{2} \max_{j,k} \{\|\mathbf{z}^{(j)} - \mathbf{z}^{(k)}\|\}, j, k = 1, 2, \dots, c$ .

(10) 计算人脸类的最大允许距离:  $T_2 = \max_i \{\max_j \{\|\mathbf{z}_j^{(i)} - \mathbf{W}_{opt}^T (\mathbf{m}_i - \mathbf{m})\|\}\}, j = 1, \dots, c, i = 1, 2, \dots, N_i$ .

(二) 识别过程

(11) 将某个待识别彩色人脸图像  $\Gamma$  采用模拟 K-L 变换而转换成灰度图像  $I$ ;

(12) 根据奇异值分解定理计算相应灰度人脸图像  $I$  对应的奇异值特征向量  $\mathbf{x}^{sv}$ .

(13) 对奇异值特征向量空间进行坐标轴平移,坐标轴平移后,待识别人脸图像对应的奇异值特征向量为  $\mathbf{x} = \mathbf{x}^{sv} - \mathbf{m}^{sv}$ .

(14) 对奇异值特征向量  $\mathbf{x}$  进行 DKL 投影变换,得到新的  $l$  维 MDF 空间中的最佳分类特征  $\mathbf{z} = (z_1, \dots, z_l)^T = \mathbf{W}_{opt}^T \mathbf{x} = \mathbf{W}_{fld}^T \mathbf{W}_{pca}^T \mathbf{x}$ .

(15) 找到和待识别图像最接近的训练集(数据库)中的人脸类.  $d_1 = \min_i \|\mathbf{z} - \mathbf{z}^{(i)}\|$ , 式中  $\|\cdot\|$  表示在特征空间中的欧几里德距离.

(16) 计算待识别图像对应的奇异值特征向量和重建奇异值特征向量之间的距离(这就是说,计算投影距离以便能够评价测试图像中含有人脸的可能性):  $d_2 = \|\mathbf{x} - \mathbf{W}_{opt} \mathbf{z} - \mathbf{m}^{sv}\|$ , 其中  $\mathbf{x}$  为待测试的人脸图像奇异值特征向量,  $\mathbf{W}_{opt} \mathbf{z} = \mathbf{W}_{pca} \mathbf{W}_{fld}^T \mathbf{z} = [\mathbf{w}_1^{pca}, \mathbf{w}_2^{pca}, \dots, \mathbf{w}_k^{pca}] [\mathbf{w}_1^{fld}, \mathbf{w}_2^{fld}, \dots, \mathbf{w}_l^{fld}]^T \mathbf{z}$ .

(17) 判别分类:

(a) 如果  $d_2 \geq T_1$ , 则表明该测试图像  $\Gamma$  为非人脸图像;

(b) 如果  $d_2 < T_1$ , 则表明测试图像  $\Gamma$  在由训练集人脸得到的奇异值特征向量空间中的投影点和人脸的奇异值特征向量投影点非常接近,因此判断该测试图像为人脸图像,进一步地:

① 如果  $d_2 < T_1$  且  $d_1 < T_2$ , 则将测试图像  $\Gamma$  归类为训练集中  $\omega_i$  类的人脸;

② 如果  $d_2 < T_1$  且  $d_1 \geq T_2$ , 则将测试图像  $\Gamma$  归类为非训练集中的人脸.

### 3 仿真结果分析

我们对本文提出的方法进行了仿真试验.实验所用的数据库为 Essex 彩色人脸图像数据库.在 Essex 彩色人脸图像数据库中选择了 40 类共 800 幅人脸图像,每类人脸图像的一半作为训练集,另一半作为测试集.因此,取自 Essex 彩色人脸图像数据库中的训练集图像共有 40 类 400 幅,测试集图像也为 40 类 400 幅.另外,我们采用基于奇异值分解的 PCA 法与 FLD 法进行比较.

图 2~图 4 分别表示各方法对应于训练集和测试集的识别率曲线.由于 Essex 数据库中每类人脸图像的训练集和测试集很相似,每类人脸图像的表情、姿态和光线等的变化都较小,因此,这 3 种方法的训练集识别率曲线和测试集识别率曲线都很相似.

相对来说,基于奇异值特征向量 PCA 法的识别率较低,最高识别率为 96.25%(如图 2 所示).其原因是由于主分量分析中提取的特征向量只是使重建图像对应的奇异值特征向量的均方误差最小.因此,一般来说,提取的这些特征向量只是最好的描述特征而不是最好的分类特征,从而导致该方法的识别率相对较低.当用前面两个特征对训练集进行识别时,识别率为 88.25%,当选用多于两个以上的大特征值对应的特征数目时,可以取得最佳识

别效果,这时识别率稳定地保持在 96.25%。而用前面两个特征对测试集进行识别时,识别率也为 88.25%,选用多于 7 个以上的大特征值对应的特征数目时可以取得最佳的识别效果,这时,识别率保持在 95%。




Fig.2 PCA method  
图2 PCA方法




Fig.3 FLD method  
图3 FLD方法




Fig.4 Our method  
图4 本文的方法

由图3可知,基于奇异值特征向量的FLD识别方法的识别率很高,当用前面两个特征对训练集进行识别时,识别率就高达96.75%,当选用多于2个以上的大特征值对应的特征数目时可以取得最佳识别效果,这时识别率稳定不变地保持在97.5%。而当用前面两个特征对测试集进行识别时,识别率为86.75%,当选用多于10个以上的大特征值对应的特征数目时可以取得最佳的识别效果,这时识别率稳定不变地保持在97.5%。

由图4可知,基于奇异值特征向量DKL识别方法的识别率很高,当用前面两个特征对训练集进行识别时,识别率就高达94.25%,当选用多于4个以上的大特征值对应的特征数目时可以取得最佳识别效果,这时识别率稳定不变地保持在97.5%。而当用前面两个特征对测试集进行识别时,识别率为91.25%,当选用多于5个以上的大特征值对应的特征数目时可以取得最佳的识别效果,这时识别率在97.5%处保持不变。

通过比较可见,这3种方法都具有识别率较高而所用的特征向量数目较小(即最终的特征空间维数低)的特点。而识别率的不同则再次证明了如下的结论,即特征脸的图像主要反映的是原始模式变化最大的成分,以使图像重建后的均方误差最小,该方法受照明条件等与人脸本身无关的因素的影响较大,选用较大特征值对应的特征向量进行识别不一定能取得预期的效果。而Fisher线性判别方法使投影后的模式样本的类间散布矩阵最大而类内散布矩阵最小,也就是说,投影后保证模式样本在新的空间中有最大的类间距离和最小的类内距离,即模式在该空间中有最佳的可分离性。Fisher线性判别分析提取的特征向量集强调的是不同人脸的差异,而不是照明条件、人脸表情和方向的变化。因而,采用FLD方法对人脸进行识别比采用PCA方法对光照条件、人脸的姿态等的变化更为不敏感,从而采用Fisher鉴别向量有助于提高识别效果。本文的方法由于综合利用了PCA方法和FLD方法的优点,因此具有最佳识别效果,即所用的特征数目少而识别率最高。

## 4 结 论

使用PCA方法和FLD方法都能大大降低原始特征空间的维数,并已在人脸识别中得到了广泛的应用;然而,PCA方法得到的特征是最佳描述特征而不是最佳分类特征,FLD方法则存在类内散布矩阵总为奇异阵而使求解变得很困难等缺点。本文提出的方法首先利用模拟K-L变换得到彩色人脸图像的主分量特征图像,然后通过奇异值分解获得奇异值特征向量,再通过主分量分析技术得到人脸的最佳描述特征,最后利用Fisher线性判别分析来得到维数更低的最佳鉴别特征。这样,既利用了特征脸方法和Fisher线性判别分析方法的优点,又克服了它们的不足之处,同时使分类器的设计更加简洁、有效,提高了人脸图像的识别率。

## References:

- [1] Zhou DL. A study of human face recognition [Ph.D. Thesis]. Xi'an: Northwestern Polytechnical University, 2001 (in Chinese with English abstract).
- [2] Chellappa R, Wilson CL, Sirohey S. Human and machine recognition of faces: A survey. Proceedings of The IEEE, 1995,83(5): 705~740.

- [3] Ohta Y, Kanade T, Sakai T. Color information for region segmentation. *Computer Graphics and Image Processing*, 1980,13: 222~241.
- [4] Hong Z. Algebraic feature extraction of image for recognition. *Pattern Recognition*, 1991,24:211~219.
- [5] Hong ZQ, Yang JY. Image algebraic feature extraction for image recognition. *Acta Automatica Sinica*, 1992,18(2):233~237 (in Chinese with English abstract).
- [6] Hong ZQ, Yang JY. Human facial image recognition algorithm based on singular value features and statistical model. *Computer Research and Development*, 1994,31(3):60~65 (in Chinese with English abstract).
- [7] Li SQ, Hou ZQ. Extraction of the embryo cardiogram signal using singular value decomposition. *Journal of Data Acquisition and Processing*, 1989,4(Supplement):12~14 (in Chinese with English abstract).
- [8] Klema VC. The singular value decomposition: Its computation and some applications. *IEEE Transactions on Automatic Control*, 1980,25(2):164~176.
- [9] Turk M, Pentland A. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 1991,3(1):71~86.
- [10] Kirby M, Sirovich L. Application of the Karhunen-Loève procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990,12(1):103~108.
- [11] Sirovich L, Kirby M. Low-Dimensional procedure for the characterization of human faces. *Journal of the Optical Society of America A*, 1987,4(3):519~524.
- [12] Etemad K, Chellapa R. Discriminant analysis for recognition of human face images. *Journal of the Optical Society of America A*, 1997,14(8):1724~1733.
- [13] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997,19(7):711~720.
- [14] Bian ZQ, Zhang CS, Zhang XG. *Pattern Recognition*. Beijing: Tsinghua University Press, 2000 (in Chinese).
- [15] Cheng YP, *et al.* *Theory of Matrix*. Xi'an: Northwestern Polytechnical University Press, 1989 (in Chinese).

#### 附中文参考文献:

- [1] 周德龙. 人脸识别技术研究[博士学位论文]. 西安:西北工业大学, 2001.
- [5] 洪子泉, 杨静宇. 用于图像识别的图像代数特征抽取. *自动化学报*, 1992,18(2):233~237.
- [6] 洪子泉, 杨静宇. 基于奇异值特征和统计模型的人像识别算法. *计算机研究与发展*, 1994,31(3):60~65.
- [7] 李淑秋, 侯自强. 用奇异值分解法提取微弱的胎儿心电信号. *数据采集与处理*, 1989,4(增刊):12~14.
- [14] 边肇祺, 张长水, 张学工. *模式识别*. 北京:清华大学出版社, 2000.
- [15] 程云鹏, 等. *矩阵论*. 西安:西北工业大学出版社, 1989.