

基于分块 2DPCA 与 2DLDA 的单训练样本人脸识别

覃 磊^{1,2}, 李德华¹, 周 康²

(1 华中科技大学 自动化学院, 湖北 武汉 430074; 2 武汉轻工大学 数学与计算机学院, 湖北 武汉 430023)

摘 要: 二维线性判别分析(2DLDA)在人脸识别已经获得巨大成功,然而用于单训练样本人脸识别问题方法失效.因为每类需要多个样本计算类内散度.对此提出了一种新的基于图像矩阵的分块二维主成分分析+二维线性判别分析(Block 2DPCA+2DLDA)的单训练样本人脸识别算法.首先将图像进行分块,并按其位置将子图像分成多个样本集,在每个样本集上应用 2DPCA 算法,进行第一次识别.其次将第一次识别出的已知类别的测试样本并入原单训练样本集中,原单训练样本集成为多训练样本集.最后在新的训练样本集和测试集上应用 2DLDA 算法作为第二次识别,识别第一次未能识别出的图像. Block 2DPCA+2DLDA 算法在 ORL 人脸数据库上被检测,实验结果表明 Block 2DPCA+2DLDA 识别结果优于 PCA、2DPCA 等算法.

关键词: 单训练样本;人脸识别;二维主成分分析(2DPCA);二维线性判别分析(2DLDA)

中图分类号: TP393

文献标识码: A

文章编号: 1000-7180(2015)11-0105-06

Single Training Sample Face Recognition Based on Block 2DPCA and 2DLDA

QIN Lei^{1,2}, LI De-hua¹, ZHOU Kang²

(1 School of Automation, Huazhong University of Science and Technology, Wuhan 430074, China;

2 School of Mathematics and Computer, Wuhan Polytechnic University, Wuhan 430023, China)

Abstract: Two-dimensional linear discriminant analysis (2DLDA) has achieved great success in face recognition, however, it fails to work for single training sample face recognition, since it need more than one sample per person to estimate the within-class scatter. This paper proposes a novel single training sample face recognition algorithm based on Block 2DPCA+2DLDA. At first, the original images are divided into some sub-images, according to the locations of the sub-images they are divided into multiple sample sets, 2DPCA is applied on each sample set for the first recognition. The test samples which have been identified after the first recognition are added to the original training sample set as the samples of known class labels, and the original single training sample set will become a multiple training samples set. Finally 2DLDA is used in the new training sample set and test set for the second recognition, which is to identify the images that are not recognized on the first time. The Block 2DPCA+2DLDA algorithm is tested on the ORL face database, the experiment results show that the algorithm is better than PCA and 2DPCA algorithms etc.

Key words: Single training sample; face recognition; 2DPCA; 2DLDA

1 引言

人脸识别是模式领域研究热点之一,主成分分

析(PCA)、独立成分分析、Gabor 小波变换、二维线性判别分析(2DLDA)等方法被提出^[1-4].这些方法往往需要每个模式类有多个样本,但在一些实际应

收稿日期: 2015-01-30; 修回日期: 2015-03-21

基金项目: 国家自然科学基金(61179032, 61072143); 湖北省自然科学基金(11CDB229); 武汉轻工大学科研计划项目(2015y03; xsky2015032)

用特殊场景往往只能提供少量甚至单样本,如护照、身份验证、法律实施等场景。这时 2DLDA 等传统算法的性能大幅下降甚至失效。近来有关学者对单训练样本人脸识别问题提出了一些算法。Wu Jianxin 和 Zhou Zhihua 提出 $(PC)^2A$ 算法,计算原图像的投影,结合原图像构建投影结合的图像,最后将 PCA 应用于投影结合的图像,其实质是一种投影滤波的 PCA 算法^[5]。Chen Songcan 等改进 $(PC)^2A$,提出了 $E(PC)^2A$ 算法,引入图像的一阶、二阶甚至 n 阶投影,应用 PCA 于投影图像、投影结合的图像^[6]。Zhang Daoqiang 等提出了一种基于奇异值扰动的单样本人脸识别算法,算法能有效地提高识别率,降低存储要求^[7]。Gao Quanyue 等提出了一种基于奇异值分解的 FLDA 算法,通过图像矩阵的奇异值分解,构造虚拟图像将单训练样本问题转化为多训练样本问题,然后应用 FLDA 算法^[8]。

与上述文献不同的是,本文的关键处不在于构造虚拟样本来扩充训练样本或其他方式,而在于从测试样本中识别出真实的,与训练样本的类别一致的样本来扩充训练样本集,提出了基于 Block 2DPCA+2DLDA 的单训练样本人脸识别算法。首先将原样本集进行分块,形成不同的子块样本集,在每个子块样本集上应用 2DPCA 算法^[9],比较识别结果作为第一次识别。将第一次识别出的训练样本作为已知类标签的样本被加入到原单训练样本集中,相当于对单训练样本集进行了扩充,在扩充后的新的训练集和测试集上应用 2DLDA 算法,进行第二次识别,将第二次识别结果结合第一次识别结果作为最终的识别结果。

2 2DPCA

2.1 投影轴的建立

设图像 $A \in R^{m \times n}$, $X \in R^{n \times 1}$ 为 n 维单位列向量,通过

$$Y = AX \quad (1)$$

将 A 投影到 X 上得到投影向量 Y 。2DPCA 就是求最大化投影样本的全局散度的坐标轴。全局散度一般用 $J(X) = \text{tr}(TS_X)$ 来表示,其中 TS_X 定义为训练样本的投影特征向量的散度矩阵, $\text{tr}(TS_X)$ 为矩阵 TS_X 的迹。设有来自 L 个模式类的 M 个训练样本图像,第 i 个模式类 T_i 有 N_i 个图像, T_i 类的第 j 个图像用 A_i^j 表示, $\bar{A}$ 表示所有训练样本的平均样本, $\bar{A}_i$ 表示 T_i 类样本的平均样本。 $J(X)$ 可描述为 $J(X) = \text{tr}(TS_X) = X^T [E(A - EA)^T(A - EA)]X$

$$= X^T G_i X \quad (2)$$

其中

$$G_i = E(A - EA)^T(A - EA) = \sum_{i=1}^L \sum_{j \in T_i} (A_i^j - \bar{A}_i)^T (A_i^j - \bar{A}_i).$$

G_i 为图像的全局散度矩阵, X 是一个单位列向量。最大化 $J(X)$ 的向量 X 称为最优投影轴,最大化 $J(X)$ 是为了投影后的投影样本的全局散度达到最大。

最优投影轴 X_{opt} 是 G_i 的最大特征值对应的特征向量。通常选取一个投影轴集合 $X_1, X_2, \dots, X_d$, $X_1, X_2, \dots, X_d$ 实质为 G_i 的最大的 d 个特征值所对应的正交特征向量,记 $X = (X_1, X_2, \dots, X_d)$ 。

2.2 特征提取

对于任意一个图像,将其投影到 2.1 节得到的投影轴集合 X 上,求出 $Y = (Y_1, Y_2, \dots, Y_d) = AX = A(X_1, X_2, \dots, X_d)$, Y 即为图像的特征矩阵。训练时,将所有的训练样本投影到投影轴矩阵 X 上,得到它们的特征矩阵。测试时,将每一幅测试样本图像投影到投影轴矩阵上,得到其特征矩阵。

2.3 分类

对于任意两特征矩阵, $Y^{(i)} = (Y_1^{(i)}, Y_2^{(i)}, \dots, Y_d^{(i)})$, $Y^{(j)} = (Y_1^{(j)}, Y_2^{(j)}, \dots, Y_d^{(j)})$, 最近邻分类器被采用, $Y^{(i)}$ 和 $Y^{(j)}$ 的距离为 $d(Y^{(i)}, Y^{(j)}) = \sum_{k=1}^d \|y_k^{(i)} - y_k^{(j)}\|_2$ 。对于给定的测试图像特征矩阵 Y , 若 $d(Y, Y_k) = \min_j d(Y, Y_j)$ 且 $Y_k \in T_i$, 则 $Y \in T_i$ 。

3 2DLDA

通过式(1)将 A 投影到 X 上得到投影向量 Y 。2DLDA 就是寻求最大化投影样本的类间散度和类内散度的比值的投影轴,比值表示式如下:

$$J(X) = \frac{\text{tr}(TS_B)}{\text{tr}(TS_W)} \quad (3)$$

其中

$$TS_B = \sum_{i=1}^L N_i (\bar{Y}_i - \bar{Y})(\bar{Y}_i - \bar{Y})^T = \sum_{i=1}^L N_i [(\bar{A}_i - \bar{A})X] \cdot [(\bar{A}_i - \bar{A})X]^T,$$

$$TS_W = \sum_{i=1}^L \sum_{j \in T_i} (Y_i^j - \bar{Y}_i)(Y_i^j - \bar{Y}_i)^T = \sum_{i=1}^L \sum_{j \in T_i} [(A_i^j - \bar{A}_i)X] \cdot [(A_i^j - \bar{A}_i)X]^T$$

所以 $tr(TS_B) = \mathbf{X}^T (\sum_{i=1}^L N_i (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A})) \mathbf{X} = \mathbf{X}^T S_B \mathbf{X}$,

$$tr(TS_W) = \mathbf{X}^T (\sum_{i=1}^L \sum_{j \in T_i} (A_i^j - \bar{A})^T (A_i^j - \bar{A})) \mathbf{X} = \mathbf{X}^T S_W \mathbf{X}.$$

最大化式(3)即为求解广义特征值问题 $S_B \mathbf{x} = \lambda S_W \mathbf{x}$, 最优投影轴 $X_1, X_2, \dots, X_d$ 为 $S_W^{-1} S_B$ 的最大 d 个特征值对应的正交特征向量, 记 $\mathbf{X} = (X_1, X_2, \dots, X_d)$. 2DLDA 的特征提取和分类与 2DPCA 相同.

4 分块 2DPCA + 2DLDA

4.1 2DPCA 进行第一次识别

首先将每个 $m \times n$ 的图像 A 分成 $p \times q$ 块, 即 A

$$= \begin{bmatrix} A_{11} & A_{12} & \cdots & A_{1q} \\ A_{21} & A_{22} & \cdots & A_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ A_{p1} & A_{p2} & \cdots & A_{pq} \end{bmatrix} \quad \text{其中每个子图像 } A_{ij} \text{ 是 } m_1$$

$\times n_1$ 的矩阵, $m_1 = m/p, n_1 = n/q$, 为便于处理, 本文取定 $p = 2, q = 2$. 给定 M 幅训练图像 $A^{(1)}, A^{(2)}, \dots, A^{(M)}$, 和 N 幅测试图像 $\hat{A}^{(1)}, \hat{A}^{(2)}, \dots, \hat{A}^{(N)}$, 对它们分块后有

$$A^{(1)} = \begin{bmatrix} A_{11}^{(1)} & \cdots & A_{1q}^{(1)} \\ \vdots & \ddots & \vdots \\ A_{p1}^{(1)} & \cdots & A_{pq}^{(1)} \end{bmatrix}, \dots, A^{(M)} = \begin{bmatrix} A_{11}^{(M)} & \cdots & A_{1q}^{(M)} \\ \vdots & \ddots & \vdots \\ A_{p1}^{(M)} & \cdots & A_{pq}^{(M)} \end{bmatrix},$$

$$\hat{A}^{(1)} = \begin{bmatrix} \hat{A}_{11}^{(1)} & \cdots & \hat{A}_{1q}^{(1)} \\ \vdots & \ddots & \vdots \\ \hat{A}_{p1}^{(1)} & \cdots & \hat{A}_{pq}^{(1)} \end{bmatrix}, \dots, \hat{A}^{(N)} = \begin{bmatrix} \hat{A}_{11}^{(N)} & \cdots & \hat{A}_{1q}^{(N)} \\ \vdots & \ddots & \vdots \\ \hat{A}_{p1}^{(N)} & \cdots & \hat{A}_{pq}^{(N)} \end{bmatrix}$$

M 幅训练图像和 N 幅测试图像生成 Mpq 幅训练子图像和 Npq 幅测试子图像. 所有子图像按位置分为 pq 个子图像集, 2DPCA 被用于每个子图像集, 具体而言, 处在第 i 行第 j 列的所有子图像作为第 $i \times j$ 组训练样本和测试样本, 即将 $A_{ij}^{(1)}, A_{ij}^{(2)}, \dots, A_{ij}^{(M)}$ 作为训练样本, 将 $\hat{A}_{ij}^{(1)}, \hat{A}_{ij}^{(2)}, \dots, \hat{A}_{ij}^{(N)}$ 作为测试样本, 应用 2DPCA 算法于第 $i \times j$ 组样本得到 N 个测试子

图像的识别结果 $C^{(ij)} = [C_{ij}^{(1)}, C_{ij}^{(2)}, \dots, C_{ij}^{(N)}], i = 1, 2, \dots, p; j = 1, 2, \dots, q$; 所有的第一次识别结果组成矩阵, 即为

$$C = \begin{bmatrix} C^{(1)} \\ C^{(2)} \\ \vdots \\ C^{(pq)} \end{bmatrix} = \begin{bmatrix} C_{11}^{(1)} & C_{11}^{(2)} & \cdots & C_{11}^{(N)} \\ C_{12}^{(1)} & C_{12}^{(2)} & \cdots & C_{12}^{(N)} \\ \vdots & \vdots & \ddots & \vdots \\ C_{pq}^{(1)} & C_{pq}^{(2)} & \cdots & C_{pq}^{(N)} \end{bmatrix}.$$

式中, $C_{ij}^{(k)}$ 表示原测试集中第 k 个测试图像的第 $i \times j$ 个子图像的分类. 对第一次识别结果矩阵 C 的第一列开始按列比对, 若列的各元素均相等, 即若

$$C_{11}^{(k)} = C_{12}^{(k)} = \cdots = C_{pq}^{(k)} = t, t \in T_a, k = 1, 2, \dots, N \quad (4)$$

则表明第 k 幅测试图像的所有子图像属于同一类, 即第 T_a 类, 将此测试图像挑出, 作为已知类别标签 (第 T_a 类) 的样本并入到原来的单训练样本集. 这么认定源于一个简单事实, 在光照、旋转、姿势变化都不大的情况下, 若两幅不同图像是属于同一类的, 即它们是来自一个人的两幅不同图像, 那么这两幅图像位于相同位置的子图像应该是成对最相似的; 反之, 若两幅图像不是属于同一类的, 即它们不是来自同一个人的图像, 那么这两幅图像的位于同样位置的子图像不可能都成对相似. 若有训练图像 $A^{(1)}$

和测试图像 $\hat{A}^{(1)}$ 是来自于同一个人的两幅不同图像, 那么这两幅图像的位于相同位置的子图像, 即 $A_{11}^{(1)}$ 和 $\hat{A}_{11}^{(1)}, A_{12}^{(1)}$ 和 $\hat{A}_{12}^{(1)}, \dots, A_{pj}^{(1)}$ 和 $\hat{A}_{pj}^{(1)}$ 应该是最相似的.

因为每类只有一个训练样本, 所以式(4)中的 $C_{ij}^{(k)} = t, t \in T_a$ 指第 k 个测试图像的第 i 行第 j 列的子图像是属于 T_a 类的, 表明第 k 个测试图像的第 i 行第 j 列的子图像和第 T_a 类单训练样本图像的第 i 行第 j 列的子图像是最相似的. 式(4)指认定第 k 个测试图像的所有 pq 个子图像属于第 T_a 类, 表明第 k 个测试图像的所有 pq 个子图像分别和第 T_a 类的单训练样本图像的所有 pq 个子图像是两两最相似的, 可认定此测试图像就是属于第 T_a 类, 下面从概率意义上解释这点.

设有测试图像 $\hat{A}^{(k)}$, 则 $P\{\hat{A}^{(k)} \in T_a\} = P\{\hat{A}_{11}^{(k)} \in T_a, \hat{A}_{12}^{(k)} \in T_a, \dots, \hat{A}_{pq}^{(k)} \in T_a\} = P\{\hat{A}_{11}^{(k)} \in T_a\} P\{\hat{A}_{12}^{(k)} \in T_a\} \cdots P\{\hat{A}_{pq}^{(k)} \in T_a\}$, 此式表明, 只有当 $\hat{A}_{11}^{(k)} \in T_a, \hat{A}_{12}^{(k)} \in T_a, \dots, \hat{A}_{pq}^{(k)} \in T_a$ 都成立的条件下方能得出测试图像 $\hat{A}^{(k)} \in T_a$ 的结论. 因为 $P\{\hat{A}^{(k)} \in T_a\}$ 等于 pq 个概率的乘积, 得到 $\hat{A}^{(k)} \in T_a$

结论的概率是相当小的,尤其是在事实是 $A^{(k)} \notin T_a$ 的情况下,此概率接近为零.因此如果第一次识别结果矩阵 C 的第 k 列满足式(4),则可确定此测试样本 $A^{(k)}$ 是第 T_a 类的,后续实验结果也表明,在式(4)成立时做出测试样本 $A^{(k)}$ 属于 T_a 类的结论与实际情况是吻合的,即实际情况是此测试样本是 T_a 类.

既然确定第 k 幅测试图像 $A^{(k)} \in T_a$,则可把 $A^{(k)}$ 作为第 T_a 类的增补的训练样本,加入到原单训练样本集中.将所有满足式(4)的测试图像加入到原单训练样本集各自所属的类中,原单训练样本集将会成为一个一般的多样本训练集.这个新的训练集图像包含两部分:一部分为原来的单训练样本集,即初始时的每类一副图像;另一部分为经第一次 Block 2DPCA 识别后所识别出的那些测试图像.需要识别的图像仅为原测试集经过第一次识别后剩下的图像,即原测试集中不满足条件式(4)剩下的图像,它们将被作为新的测试集进行第二次识别.

4.2 2DLDA 算法进行第二次识别

经过第一次识别后原识别问题已转为一个一般的多训练样本的识别问题,则可用传统的人脸识别算法对新的样本集进行特征提取和识别.2DLDA 可直接处理图像矩阵,不同于特征脸、费歇尔脸等算法,图像矩阵不需转化为向量,这往往会造成散度矩阵的维数相当大,2DLDA 的散度矩阵一般很小,而且文献[4]中表明 2DLDA 算法的识别率等性能特征要超过特征脸、费歇尔脸等算法.综合以上因素,选择 2DLDA 算法进行第二次识别,具体过程如下,首先,在第一次识别后生成的新的训练集上应用 2DLDA 算法提取投影轴;然后应用投影轴对新的训练集和测试集进行投影,提取投影特征矩阵;最后,用最近邻分类器用于识别分类.

5 实验与分析


选用 ORL 人脸数据库进行算法的检测,ORL 数据库包括 40 个人,每人 10 幅一共 400 幅人脸图像,照片拍摄于不同的时间.在一定范围内存在光照、面部表情变化(如睁眼或闭眼、微笑或不微笑)以及脸部细节变化(如是否戴眼镜).所有照片都是正面直立,头部甚至还有一定程度倾斜和转动,转动角度不超过 20 度,图像为 112×92 灰度图像^[10].

本文首先比较 Block 2DPCA+2DLDA 和前文提到的 2DPCA、SVD-based FLDA、PCA、SPCA 和


E(PC)²A 随投影轴数变化的识别率,每人任选一幅图像作为训练图像,其余图像作为测试图像,共有 40 幅训练样本,360 幅测试样本.为了客观比较算法的差异,所有算法都是在相同的训练样本集和测试样本集上进行训练和测试.

对于 Block 2DPCA 算法,第一次识别后所识别出的测试样本图像与它们的实际对应类别完全相同,这也验证了 4.1 节中的分析,Block 2DPCA 可以准确确定一些测试样本的所属类别.

对于上述的二维特征提取算法,即 2DPCA、SVD-based FLDA 和本文算法,10 个投影轴被提取,以 1 为步长,画出了随投影轴数增加的识别率的变化图.对于一维特征提取算法,即 PCA、SPCA 和 E(PC)²A,40 个投影轴被提取,以 5 为步长,画出了随投影轴数增加的识别率的变化图,见图 1.



(a)



(b)

图 1 随投影轴数变化的六种算法的识别率

从图 1 可以看出,Block 2DPCA+2DLDA 算法的识别精度明显超过了其他二维和一维特征提取算法.当投影轴数较小时,Block 2DPCA+2DLDA 算法的识别精度超出 2DPCA 和 SVD-based FLDA 的二维算法比较明显,投影轴数较小将产生较小的特

征矩阵,这对于后续的存储、计算等处理是有利的.随着特征轴数的增加,虽然 Block 2DPCA+2DLDA 的识别率有所下降,但依然高于 2DPCA 和 SVD-based FLDA. 从表 1 中也可以看出,2DPCA 和 SVD-based FLDA 的最高识别率分别为 78.06% 和 76.94%,而 Block 2DPCA+2DLDA 最高识别率为 81.39%,超出 3.33 和 4.45 个百分点. 至于一维特征提取算法 PCA、SPCA 和 $E(PC)^2A$,图 1 显示对比 Block 2DPCA+2DLDA 的识别率,差距更为明显,虽然一维算法的识别率随投影轴数的增加而增加,然后不管取多少投影轴,SPCA 和 $E(PC)^2A$ 的识别率都在 70% 以下,PCA 算法只有当投影轴数在 35 或 35 以上时,识别率才能达到 70%,Block 2DPCA+2DLDA 识别率都在 75% 以上. PCA、SPCA 和 $E(PC)^2A$ 的最高识别率只能达到 71.39%、63.06% 和 68.89% 的识别率,离 Block 2DPCA+2DLDA 最高识别率 81.39% 仍相差十个百分点甚至以上,具体数据见表 1.

表 1 六种算法的比较

算法	最优投影轴的个数	特征矩阵维数	识别率/%
PCA	39	39×1	71.39
SPCA	37	37×1	63.06
$E(PC)^2A$	37	37×1	68.89
2DPCA	5	112×5	78.06
SVD-based FLDA	6	112×6	76.94
Block 2DPCA+2DLDA	2	112×2	81.39

Block 2DPCA+2DLDA 超出其地算法的原因是,对于一维特征提取算法 PCA、SPCA 和 $E(PC)^2A$ 算法,训练前需要将图像矩阵通过行或列相连将其转化为向量,这个过程有可能破坏图像的内部结构,造成后续提取特征不可能准确反映每类样本的本质属性. 对于二维特征提取算法 2DPCA 和 SVD-based FLDA,首先,2DPCA 仅仅考虑了样本的全局散度,因每类只有一个样本,不能直接计算样本的类内散度,SVD-based FLDA 是通过图像矩阵的奇异值分解构造虚拟训练样本,将原单训练样本集扩充为每类有两样本,从而计算样本类内散度,但增添的是虚拟样本,不是真实样本,无法精确计算类内散度. Block 2DPCA+2DLDA 是首先通过 Block 2DPCA 算法从测试样本找到准确样本作为新增训练样本,实验结果也表明第一次识别出的测试样本的类别是准确的,补充它们到原单训练样本集各自

的类中,原单训练样本集被转化为一个多样本训练集,再用 2DLDA 来考虑类内散度和全局散度,这无疑要比文献[6]中计算类内散度和全局散度要准确很多,因为经过第一次测试后得到的训练集是客观的多样本训练集,不是通过“虚构”而成的多样本训练集.

为了检验算法对不同大小样本集的鲁棒性,选取了不同数目的样本测试. 以 10 为步长,分别选取 ORL 数据库的前 10 人、前 20 人、前 30 人和所有 40 人训练和测试,任选一幅图像/人作为训练样本,其余 9 幅图像作为测试样本. 测试结果如图 2 所示,图 2 中横坐标样本集大小 1、2、3、4 分别对应前 10、20、30、40 人的情况.




图 2 逐步增加的样本集的最高识别率

图 2 显示当样本集较小时,仅 10 人、20 人时,包括 Block 2DPCA+2DLDA 等二维算法都有较好的识别效果. 随着样本集的逐渐增大,所有算法的识别率都基本呈现下降的趋势,但不论样本集的大小为多少,Block 2DPCA+2DLDA 都优于或者等效于其它算法.

6 结束语

本文提出一种新的算法 Block 2DPCA+2DLDA,相对于 PCA、2DPCA,及其扩展算法等,Block 2DPCA+2DLDA 优势如下:(1)不同于传统的构造虚拟样本的算法来扩充训练样本集,Block 2DPCA+2DLDA 不构造虚拟样本,是先从测试样本中找到对应类别的真实样本来扩充训练样本集,而且从理论和实验验证该策略的有效性;(2)不同于传统的 PCA、2DPCA 等算法仅考虑样本集的全局散度的特点,Block 2DPCA+2DLDA 的第二次识别是通过 2DLDA 实现,考虑了样本集的类内散度和类间散度,更有利于区分样本.

未来 Block 2DPCA+2DLDA 可以从以下几方面继续探讨:(1)既然它已经用于单训练样本人脸识别问题,也可以考虑将其应用于其他的如掌纹、指纹等单样本甚至小样本生物特征识别问题;(2)给研究者们提供了全新的“二次识别”的思路,考虑到 2DPCA 和 2DLDA 都属于线性投影的方法,可能会出现“过学习”,未来可考虑应用不是线性投影的其他系列的算法进行二次识别,这样可能达到更好的识别效果。

参考文献:

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86.
- [2] 吴延海,梁文莉. 基于 Gabor 小波变换的 ICA 人脸识别算法研究[J]. 微电子学与计算机, 2013, 30(7): 141-144.
- [3] 杨颖娴. 基于 PCA 算法和小波包变换的人脸识别技术[J]. 微电子学与计算机, 2011, 28(1):92-94.
- [4] Li Ming, Yuan Baozong. 2D-LDA: A statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26(5):527-532.
- [5] Wu Jianxin, Zhou Zhihua. Face recognition with one training image per person[J]. Pattern Recognition Letters, 2002, 23(14):1711-1719.
- [6] Chen Songcan, Zhang Daoqiang, Zhou Zhihua. Enhanced

(PC)2A for face recognition with one training image per person[J]. Pattern Recognition Letters, 2004, 25(10): 1173-1181.

- [7] Zhang Daoqiang, Chen Songcan, Zhou Zhihua. A new face recognition method based on SVD perturbation for single example image per person[J]. Applied Mathematics and Computation, 2005, 163(2):895 - 907.
- [8] Gao Quanyue, Zhang Lei, David Zhang. Face recognition using FLDA with single training image per person [J]. Applied Mathematics and Computation, 2008, 205(12):726-734.
- [9] Yang Jian, David Zhang, Frangi A F, et al. 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.
- [10] The ORL Face Database[EB/OL]. [2014-04-20]. <http://www.uk.research.att.com/facedatabase.html>.

作者简介:

覃磊 男, (1979-), 博士研究生, 讲师. 研究方向为模式识别与智能计算. E-mail: 53039943@qq.com

李德华 男, (1946-), 教授, 博士生导师. 研究方向为模式识别与人工智能.

周康 男, (1965-), 博士, 教授. 研究方向为模式识别.

(上接第 104 页)

参考文献:

- [1] 范彬, 杨华. 动态变形伪装对相关跟踪的干扰效果研究[J]. 航天电子对抗, 2006, 22(4):49-51.
- [2] 周桢. 复杂场景中目标抗遮挡跟踪方法研究. 航空兵器[J], 2007, 12(6):36-39.
- [3] 刘士荣, 朱伟涛, 杨帆, 等. 基于多特征融合的粒子滤波目标跟踪算法[J]. 信息与控制, 2012, 41(6): 752-759.
- [4] 陈善静, 杨华, 曾凯, 等. 基于线性最小二乘估计与中心距离加权的相关跟踪算法研究[J]. 电光与控制, 2011, 18(2):77-80.

- [5] 杨晓峰, 张桂林. 一种基于仿射变换模型的目标跟踪算法[J]. 计算机与数字工程, 2005, 33(12):30-34.

作者简介:

冯俊惠 女, (1988-), 硕士研究生. 研究方向为图像处理、目标跟踪. E-mail: junhui_feng@163.com

肖阳辉 男, (1968-), 研究员, 硕士生导师. 研究方向为光电成像、图像处理、目标识别等.

王恩德 男, (1980-), 博士研究生. 研究方向为模式识别、图像处理.

杨凯 男, (1988-), 硕士研究生. 研究方向为图像处理、计算机视觉.