

双向压缩二维特征抽取人脸识别新方法

郭志强 杨杰

(武汉理工大学信息工程学院 武汉 430070)

摘要 提出了二维主成分分析(2DPCA)与二维线性鉴别分析(2DLDA)相结合的双向压缩投影的子空间人脸识别方法。该方法在进行一次2DPCA运算后,对特征矩阵进行转置,再进行2DLDA运算,与 $(2D)^2$ PCA与 $(2D)^2$ LDA相比,充分利用了2DPCA和2DLDA的优点,既包含了样本的类别信息,又消除了图像矩阵行和列的相关性,有效地提取了行和列的识别信息,识别特征维数也大幅度减少。在ORL和PERET人脸库上的实验表明,在不影响识别速度的情况下,其识别率优于现有二维特征提取方法。

关键词 人脸识别,二维线性鉴别分析,二维主成分分析

中图分类号 TP391.4 **文献标识码** A

New Method of Two Direction and Two Dimension Extract Features for Face Recognition

GUO Zhi-qiang YANG Jie

(School of Information Engineering, Wuhan University of Technology, Wuhan 430070, China)

Abstract Two-way compression project subspace method combining both the Two-dimension Principle Component Analysis (2DPCA) and the Two-dimension Linear Discriminant Analysis (2DLDA) was proposed for face recognition. This method first transposes the feature matrix after it performs the 2DPCA and then it performs the 2DLDA. Compared with the $(2D)^2$ PCA and $(2D)^2$ LDA, this method makes full use of the advantages of the 2DPCA and 2DLDA. It not only contains the sample category information, but also eliminates the image matrix correlation of the row and column, so that it effectively extracts the row and column recognition information, and meanwhile, the recognition feature dimension decreases dramatically. The experiment on the ORL and PERET face databases shows that the recognition rate of this method is better than the existing two-dimension feature extract method without influencing the recognition speed.

Keywords Face recognition, Two dimension linear discriminant analysis, Two principle component analysis

特征提取是人脸识别的关键,基于子空间的人脸图像特征提取方法是当前的主流。1991年, Turk^[1]提出了著名的Eigenface方法;1997年, Belhumeur^[2]利用线性鉴别思想提出了fisherface(PCA+LDA)方法。这两种方法因其理论基础坚实、实现简单、识别率稳定而备受人们的青睐,成为人脸特征提取的经典方法。但这两种方法的共同缺点都是先要将图像转换成一维向量,因此原始数据的特征维数较高,造成了计算上的困难。LDA由于类内散布矩阵奇异,产生了所谓的高维小样本问题。鉴于以上原因,有学者直接用图像矩阵构建产生矩阵,提出了基于图像矩阵的人脸识别方法。

1 人脸识别的二维特征提取

2002年 Yang^[3]提出了2DPCA的特征提取方法,2004年 Li^[4]提出了2DLDA的识别方法。基于图像矩阵的人脸识别方法,采用图像矩阵直接构建样本的协方差矩阵、类内散布矩阵和类间散布矩阵,避开了把图像变成一维向量,在不影响识

别率的同时,大大加快了特征提取的速度。但 Wang^[5]的研究表明,基于图像矩阵的人脸识别方法本质上是对图像做水平方向上的压缩,从而使图像水平方向特征去相关,但垂直方向特征仍是相关的,所以其识别率并不高,也不是很稳定。针对上述问题, S. Noushath^[6]和 Zhang^[7]分别提出了对角LDA和对角PCA方法,识别率有所提高,但需要构造对角图像。最近 Zhang^[8]和 S. Noushath^[9]又分别提出双向压缩的二维特征提取方法,即 $(2D)^2$ PCA和 $(2D)^2$ LDA。双向投影方法在水平和垂直两个方向进行压缩,使提取的特征维数大大减少,同时使人脸图像特征在两个方向上去相关,取得了较好的效果。 $(2D)^2$ PCA本质上仍是重建意义上的数据最优表示,并不包含类别信息。 $(2D)^2$ LDA虽然含有类别信息,但从数据表示角度不是最优的。因此本文将2DPC与2DLDA相结合,提出了2DPCA+2DLDA双向二维人脸图像特征提取方法,在ORL和PERET两个库上进行了仿真实验,验证了针对不同的应用环境下这两种方法优于现有的双向投影特征提取方法。

到稿日期:2008-12-15 返修日期:2009-03-09 本文受国家自然科学基金(50775167),湖北省科技攻关项目(2007A101c52)资助。

郭志强(1976-),男,博士研究生,讲师,主要研究方向为图像处理和模式识别, E-mail: guozhiqiang@whut.edu.cn; 杨杰(1960-),女,博士,教授,主要研究方向为图像处理等。

2 二维投影特征提取的基本原理

设有 k 类已知训练样本, 每类有 N_i 个训练样本, 共有 N 个训练样本。 X_{ij} 代表第 i 类第 j 个训练样本, 设 X_{ij} 的大小为 $m \times n$, 全体训练样本的均值为 \bar{X} , 第 i 类训练样本的均值为 \bar{X}_i , 如下定义训练样本的类间散布矩阵 S_B 、类内散布矩阵 S_W 和整体散布矩阵 S_T :

$$S_B = \sum_{i=1}^k N_i (\bar{X}_i - \bar{X})^T (\bar{X}_i - \bar{X}) \quad (1)$$

$$S_W = \sum_{i=1}^k \sum_{j=1}^{N_i} (X_{ij} - \bar{X}_i)^T (X_{ij} - \bar{X}_i) \quad (2)$$

$$S_T = S_B + S_W \quad (3)$$

2DPCA 与 2DLDA 分别定义如下准则函数:

$$J_1(\omega) = \omega^T S_T \omega \quad (4)$$

$$J_2(\omega) = \frac{\omega^T S_B \omega}{\omega^T S_W \omega} \quad (5)$$

其中, ω 为一列向量。使函数 $J_1(\omega)$ 和 $J_2(\omega)$ 最大化的向量 ω 称为最佳鉴别矢量。如果 S_W 非奇异, 则上述最优化问题可转化为求解以下特征方程:

$$S_T \omega = \lambda \omega \quad (6)$$

$$S_B \omega = \lambda S_W \omega \quad (7)$$

2DPCA 与 2DLDA 最佳鉴别矢量分别为矩阵 S_T 和 $S_W^{-1} S_B$ 最大特征值对应的特征向量。通常情况下取一个最佳矢量是不够的, 一般取前 d 最大特征值对应的一组特征向量 $\omega_1, \omega_2, \dots, \omega_d$, 组成投影矩阵 W 。训练样本和测试样本分别投影到特征空间, 得到样本的分类特征 Y_{train} 和 Y_{test} , 然后利用最近邻法进行分类。

相对于传统的 PCA 和 LDA, 2DPCA 与 2DLDA 最大的优点是采用图像矩阵直接构造类内散布矩阵、类间散布矩阵和整体散布矩阵, 加快了特征提取的速度。不足之处是: ①采用图像矩阵进行运算, 因此样本抽取的特征高达 $d \times \min(m, n)$ 维, 造成特征数据存储量增加, 也影响了分类的速度; ②2DPCA 与 2DLDA 的实质是针对图像矩阵的行向量进行 LDA 运算, 沿水平方向将人脸信息压缩到一组列向量上, 消除了人脸图像列的相关性, 人脸图像结构的行相关性仍然存在^[10], 因此影响了识别的精度。针对上述问题, Zhang 和 S. Nousath 分别提出了 (2D)²PCA 和 (2D)²LDA, 其实质是在图像的行方向和列方向顺利执行两次 2DPCA 和 2DLDA。这样, 特征维数进一步压缩, 图像行和列相关性也得到了消除。但是 2DPCA 只是图像重建意义上的最优表示, 本身并不含有类别信息, 从分类的角度上不是最优的。而 2DLDA 特征抽取的目标是寻找使类内散布矩阵最小、类间散布矩阵最大的投影方向, 算法虽含有明显的类别信息, 但从数据重建的角度上不是最优的。因此将 2DPCA 与 2DLDA 相结合, 分别对图像进行行方向和列方向的压缩投影, 一方面可以降低特征维数, 另一方面也可以充分利用 2DPCA 和 2DLDA 的优点。如经典的 fisherface 实质就是 PCA+LDA, 首先用 PCA 进行降维, 解决了 LDA 的小样本问题, 同时保留了 PCA 和 LDA 的优点, 使识别率也高于 PCA。

3 双向压缩二维特征提取

根据第 2 节的分析, 给出了 2DPCA 与 2DLDA 相结合的双向压缩二维特征提取方法, 即 2DPCA+2DLDA。算法的

基本思想是先进行一次 2DPCA, 然后对提取的特征矩阵进行转置, 再进行一次 2DLDA 运算。经过二次二维投影的运算, 消除了图像矩阵行、列的相关性。此方法包含有 2DLDA, 是一种有监督的学习方法, 它充分利用了训练样本的类别信息, 从而有利于识别率的提高。两个方向上的特征提取也使最终的特征矩阵维数较低, 加快了识别的速度。为了说明这一方法理论上的可行性, 给出以下定理。

定理 1 图像矩阵水平方向进行 2DPCA 或 2DLDA 算法等价于对图像矩阵的转置进行垂直方向的 2DPCA 或 2DLDA。

证明: 设 X_{ij} 为一 $m \times n$ 的矩阵, 表示第 i 个人第 j 张人脸图像样本, 按矩阵分块, 可转换成如下行向量和列向量。

$$X_{ij} = \begin{bmatrix} x_{ij}(1,1) & x_{ij}(1,2) & \cdots & x_{ij}(1,n) \\ x_{ij}(2,1) & x_{ij}(2,2) & \cdots & x_{ij}(2,n) \\ \vdots & \vdots & \cdots & \vdots \\ x_{ij}(m,1) & x_{ij}(m,2) & \cdots & x_{ij}(m,n) \end{bmatrix} \Rightarrow \begin{matrix} (x_{ij}(1)^R)^T \\ (x_{ij}(2)^R)^T \\ \vdots \\ (x_{ij}(m)^R)^T \end{matrix}$$

$$\Downarrow$$

$$x_{ij}(1)^c \quad x_{ij}(2)^c \quad \cdots \quad x_{ij}(n)^c \quad (8)$$

图像矩阵 X_{ij} 的转置矩阵为 X'_{ij} , 则有:

$$X'_{ij} = \begin{bmatrix} x'_{ij}(1,1) & x'_{ij}(1,2) & \cdots & x'_{ij}(1,m) \\ x'_{ij}(2,1) & x'_{ij}(2,2) & \cdots & x'_{ij}(2,m) \\ \vdots & \vdots & \cdots & \vdots \\ x'_{ij}(n,1) & x'_{ij}(n,2) & \cdots & x'_{ij}(n,m) \end{bmatrix} \Rightarrow \begin{matrix} (x'_{ij}(1)^R)^T \\ (x'_{ij}(2)^R)^T \\ \vdots \\ (x'_{ij}(n)^R)^T \end{matrix}$$

$$\Downarrow$$

$$x'_{ij}(1)^c \quad x'_{ij}(2)^c \quad \cdots \quad x'_{ij}(m)^c \quad (9)$$

显然有 $x_{ij}(r)^R = x'_{ij}(r)^c \quad r=1, 2, \dots, m$

设样本的类内均值矩阵为 \bar{X}_i , 全体样本的均值矩阵为 \bar{X} , 其转置矩阵分别为 \bar{X}'_i 和 \bar{X}' , 同理有:

$$\bar{X}_i = \begin{bmatrix} (M_i(1)^R)^T \\ (M_i(2)^R)^T \\ \vdots \\ (M_i(m)^R)^T \end{bmatrix},$$

$$\bar{X}'_i = [M'_i(1)^c \quad M'_i(2)^c \quad \cdots \quad M'_i(m)^c] \quad (10)$$

$$\bar{X} = \begin{bmatrix} (M(1)^R)^T \\ (M(2)^R)^T \\ \vdots \\ (M(m)^R)^T \end{bmatrix},$$

$$\bar{X}' = [M'(1)^c \quad M'(2)^c \quad \cdots \quad M'(m)^c] \quad (11)$$

则有:

$$M_i(r)^R = M'_i(r)^c, M(r)^R = M'(r)^c, r=1, 2, \dots, m$$

如果共有 k 类样本, 第 i 类样本个数为 N_i , 全体样本的个数为 N , 则图像矩阵的类间散布矩阵为:

$$S_B = \sum_{i=1}^k N_i (\bar{X}_i - \bar{X})^T (\bar{X}_i - \bar{X})$$

$$= \sum_{i=1}^k N_i \sum_{r=1}^m [M_i(r)^R - M(r)^R] [(M_i(r)^R)^T - (M(r)^R)^T]$$

$$= \sum_{i=1}^k N_i \sum_{r=1}^m [M'_i(r)^c - M'(r)^c] [M'_i(r)^c - M'(r)^c]^T \quad (12)$$

类内散布矩阵为:

$$S_W = \sum_{i=1}^k \sum_{j=1}^{N_i} (X_{ij} - \bar{X}_i)^T (X_{ij} - \bar{X}_i)$$

$$\begin{aligned}
&= \sum_{i=1}^k \sum_{j=1}^{N_i} \sum_{r=1}^m [(x_{ij}(r)^R)^T - (M_i(r)^R)^T]^T [(x_{ij}(r)^R)^T - (M_i'(r)^R)^T] \\
&= \sum_{i=1}^k \sum_{j=1}^{N_i} \sum_{r=1}^m [x_{ij}(r)^R - M_i(r)^R][x_{ij}(r)^R - M_i'(r)^R]^T \\
&= \sum_{i=1}^k \sum_{j=1}^{N_i} \sum_{r=1}^m [x_{ij}'(r)^c - M_i'(r)^c][x_{ij}'(r)^c - M_i'(r)^c]^T
\end{aligned} \tag{13}$$

由式(11)和式(12)可知,对图像矩阵进行水平方向的2DPCA和2DLDA算法和对图像矩阵的转置进行垂直方向的2DPCA和2DLDA算法是等价的。综上所述,2DPCA+2DLDA的算法步骤如下:

- 1)求样本的协方差矩阵 S_T 以及矩阵 S_T 的前 q 个最大特征值对应的特征向量,组成投影矩阵 $V=(v_1 \ v_2 \ \dots \ v_q)$;
- 2)求 $Y=V^T X$,则 Y 为 $m \times p$ 的矩阵;
- 3)对 Y 进行转置,求转置后矩阵的类内散布矩阵 S_w 和类间散布矩阵 S_B 以及矩阵 $S_w^{-1} S_B$ 的前 p 个最大特征值对应的特征向量,组成投影矩阵 $U=(u_1 \ u_2 \ \dots \ u_p)$;
- 4)求 $Z=YU$,则 Z 为 $q \times p$ 的矩阵,即为样本的特征矩阵。
- 5)采用最邻近法进行分类识别。

由于 p 和 q 远小于 m 和 n ,因此 Z 的维数远小于 X 和 Y 的维数,大大节省了存储空间,提高了分类的速度。

4 实验结果及分析

在 Pentium(R) 4, CPU 2.4GHz, 256M 内存, Windows XP 操作系统, Matlab6.5 环境下进行了仿真实验。实验对 2DPCA, $(2D)^2$ PCA, 2DLDA, $(2D)^2$ LDA, 2DPCA+2DLDA 进行了比较。因为主要目的是对上述 5 种方法的特征提取能力进行比较,因此分类器均采用最简单的最近邻准则,距离为欧氏距离。

4.1 YaleA 人脸库实验

YaleA 库^[11]由 15 个不同的人、每个人 11 幅图像组成,包含了较大的光照和表情的变化。对该库通过双眼定位,提取人脸部分,并把每一幅图像归一化到 46×58 。部分图像如图 1 所示。



图 1 YaleA 部分人脸图像

在 YaleA 每类训练样本取 5,对应的测试样本分别取 6,训练样本与测试样本分别为 75 和 90,实验结果的正确识别

率与投影轴数之间的关系如图 2 所示。图 2 给出了已有的 4 种方法与本文方法的识别结果。取 k 个投影轴,5 种方法的特征维数分别为 2DPCA ($112 \times k$), $(2D)^2$ PCA ($k \times k$), 2DLDA ($112 \times k$), $(2D)^2$ LDA ($k \times k$), 2DPCA+2DLDA ($k \times k$)。从实验结果可以看出,当投影轴较少时,双向投影方法由于特征维数少,因此识别率低。但随着特征维数的增加,双向投影方法的识别率迅速提高,并在维数较低的情况下就达到或超过单向投影方法。同时,还比较了上述 5 种方法在 YaleA 人脸库上实验得到最高正确识别率时的最优投影轴数、最佳鉴别特征维数、正确识别率、总的识别时间,结果如表 1 所列。表 1 中总的识别时间包含了特征提取和样本识别的时间。表 1 数据表明,在最高识别率方面 2DPCA+2DLDA 最高,正确识别率达 96.67%;在识别时间上,2DPCA+2DLDA 略高于 2DLDA,这是由于在取得最优识别率时 2DPCA+2DLDA 的投影轴数大于 2DLDA,因此识别时所用时间较长,但其最高识别率远高于 2DLDA。




图 2 YaleA 人脸库识别率随投影轴数变化的实验结果

表 1 YaleA 人脸库识别结果

比较项目	2DPCA	$(2D)^2$ PCA	2DLDA	$(2D)^2$ LDA	2DPCA+2DLDA
最优投影轴数	13	10	3	19	14
鉴别特征维数	13×58	10×10	3×112	19×19	14×14
正确识别率(%)	94.44	95.56	92.22	94.44	96.67
识别总时间/s	3.75	3.422	3.157	3.984	3.656

4.2 FERET 库实验

FERET 人脸数据库^[12]是目前世界上使用最广、最权威的人脸数据库,本实验选取其中的一个子库。该库包含 72 个人、每人 6 幅不同的图像,有较大的光照变化,也有表情和饰物的变化,并把每一幅图像归一化到 112×92 。部分图像如图 3 所示。



图 3 FERET 库部分人脸图像

在 FERET 人脸库中每类训练样本取 3,对应的测试样本分别取 3,训练样本与测试样本分别为 216。实验结果的正确识别率与投影轴数之间的关系如图 4 所示。它给出了已有的 4 种方法与本文方法的识别结果。取 k 个投影轴,5 种方法的特征维数分别为 2DPCA ($112 \times k$), $(2D)^2$ PCA ($k \times k$), 2DLDA ($112 \times k$), $(2D)^2$ LDA ($k \times k$), 2DPCA+2DLDA ($k \times$

k)。从实验结果可以看出,当投影轴较少时,双向投影方法同样由于特征维数少,因此识别率低。但随着特征维数的增加,双向投影方法的识别率迅速提高,并在维数较低的情况下就达到或超过单向投影方法。同时,还比较了5种方法在PERET人脸库上实验得到最高正确识别率时的最优投影轴数、最佳鉴别特征维数、正确识别率、总的识别时间,结果如表2所列。数据表明,在最高识别率方面2DPCA+2DLDA最高,正确识别率达90.74%,远远高于其它4种方法。在达到最高识别率时,其提取的特征最小为121维,而且其识别时间也只略高于2DLDA,因此识别效率高于其它5种方法。




图4 PERET人脸库识别率随投影轴数变化的实验结果

表2 不同维数下在PERET库识别率和识别时间的比较

比较项目	2DPCA	(2D) ² PCA	2DLDA	(2D) ² LDA	2DPCA+2DLDA
最优投影轴数	21	33	7	13	11
鉴别特征维数	21×112	33×33	7×112	13×13	11×11
正确识别率(%)	73.61	77.78	84.26	87.96	90.74
识别总时间/s	16.64	22.84	9.06	11.84	10.84

结束语 二维投影是近年来人脸图像特征提取的重要方法。本文中分析了现有几种二维投影存在的不足,提出了用2DPCA+2DLDA双向二维投影方法提取人脸有效特征。本方法保留了2DPCA和2DLDA的优点,在算法中2DLDA体现了样本的类别信息,2DPCA是图像在重建意义下的最优表示,从而最终提取的特征不仅在列、行个方向去相关,提高了提取特征的有效性,而且特征维数大大降低。实验表明,本方法优于现有的二维特征提取方法。

(上接第295页)

[3] Turk M A, Pentland A P. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86

[4] Etemad K, Chellapa R. Face recognition using discriminant eigenvectors[C]//Proceedings of the International Conference on Acoustic, Speech and Signal Processing, 1996

[5] Gottumukkal R, Asari V K. An improved face recognition technique based on modular PCA approach [J]. Pattern Recognition Letters, 2004, 25: 429-436

[6] Wiskott L, Fellous J-M, Kuiger N, et al. Face recognition by elastic bunch graph matching[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19: 775-779

[7] Ojala T, Pietikainen M, Maenpaa T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Ma-

参考文献

[1] Turk M, Pentland A. Face processing: a Models for recognition [C]//Proc. Intelligent Robots and Computer Vision VIII. SPIE, 1989, 192: 22-32

[2] Belhumeur P N, et al. Eigenfaces vs. Fisherface: Recognition using class specific linear projection[J]. IEEE Trans. Pattern Anal. Machine Intell, 1997, 19(7): 711-720

[3] Yang Jian, Zhang D. Two-dimensional PCA: A New Approach to Appearance-based Face Representation and Recognition [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2004, 24(1): 131-135

[4] Li Ming, Yuan Baozong. 2DLDA: A Statistical Linear discriminant analysis for image matrix. [J]. Pattern Recognition letters, 2005, 26: 527-532

[5] Wang Liwei, Wang Xiao, Zhang Xuerong, et al. The equivalence of two-dimension PCA to line-besde PCA[J]. Pattern Recognition letters, 2005, 26: 57-60

[6] Nousath S, Kumar G H, Shivakumara P. Diagonal fisher linear discriminant analysis for efficient face recognition[J]. Neuro-computing, 2006, 69: 1711-1716

[7] Zhang Daoqiang, Zhou Zhihua, Chen Songcan. Diagonal principal component analysis for face recognition [J]. Pattern Recognition, 2006, 39: 140-142

[8] 张生亮, 谢永华, 杨静宇. 一种双向压缩的二维特征抽取算法及其应用[J]. 计算机应用研究, 2006, 23(5): 63-69

[9] Nousath S, Kumar G H, Shivakumara P. (2D)²LDA: An efficient approach for face recognition[J]. Pattern Recognition, 2006, 39: 1396-1400

[10] 祝磊. 基于子空间分析的人脸识别研究[D]. 浙江: 浙江大学, 2007

[11] <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

[12] <http://www.itl.nist.gov/iad/humanid/feret/>

chine Intelligence, 2002, 24(7): 971-987

[8] Maenpaa T, Pietikainen M. Texture analysis with local binary patterns[M]. Chen C H, Wang P S P, eds. Handbook of Pattern Recognition and Computer Vision, 3rd edition. World Scientific, 2005: 197-216

[9] Ahonen T, Hadid A, Pietikainen M. Face description with local binary patterns: Application to face recognition [J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2006, 28(12): 2037-2041

[10] Liao Shengcai, Zhu Xiangxin, Lei Zhen, et al. Learning Multi-scale Block Local Binary Patterns for Face Recognition[C]//Proceedings of IAPR/IEEE International Conference on Biometrics (ICB-2007). Seoul, Korea, August 2007: 828-837

[11] Ahonen T, Hadid A, Pietikainen M. 8th European Conference on Computer Vision (Prague, Czech Republic, 2004). in press