

基于二维判别典型相关分析的人脸识别算法

黄丽坤 皮亦鸣

(电子科技大学电子工程学院 四川成都 610054)

摘要: 本文提出了一种新的基于典型相关分析的人脸识别算法, 叫做二维判别典型相关分析 (2D-DCCA)。该算法将2阶张量的概念引入了典型相关分析方法中。传统的典型相关分析方法中, 样本是用高维的向量表示的, 不仅计算量大, 而且常常出现内存不足, 协方差矩阵有奇异性等问题。本文算法不仅将样本的向量表达改为矩阵表达, 并且充分利用样本的类内和类间信息来优化目标函数, 从而使得该算法获得了诸多优点: 首先, 使得学习出的子空间维数降低, 从而计算量和计算时间都大大减少; 其次, 有效地避免了协方差矩阵的奇异性问题; 最后, 由于目标函数的优化利用了样本的类信息, 从而更有利于最邻近分类器进行判别。实验表明, 在人脸角度变化时, 该方法具有稳定的识别性能。

关键词: 典型相关分析; 2阶张量; 判别分析; 特征提取; 人脸识别

中图分类号: TN911.73 **文献标识码:** A **文章编号:** 1003-0530(2010)07-1055-05

Two-Dimensional Discriminant Canonical Correlation Analysis for Face Recognition

HUANG Li-kun PI Yi-ming

(The University of Electronic Science and Technology of China Chengdu 610054)

Abstract: We present a face recognition method called two-dimensional discriminant canonical correlation analysis (2D-DCCA) which is based on Canonical Correlation Analysis (CCA). The main idea is that the concept of two order tensor is combined with CCA in this paper. A sample is usually represented as a vector in the conventional CCA method which consumes lots of memory and has the singular problem. The proposed method not only makes full use of the information of within-class and between-class, but also the samples here are represented as the matrices. Hence the proposed method has these advantages: low dimensional subspace, efficient computation and the singular problem is totally avoided. The objective functions are optimized by using the information of within-class and between-class, so the accuracy of face recognition improves in the nearest neighborhood classifier. The result of the following experiments shows that the proposed method is robust when the pose of the face varies.

Key words: Canonical Correlation Analysis (CCA); two order tensor; discriminant analysis; feature extraction; Face recognition

1 引言

作为一种特征提取的有效方法, 典型相关分析 (CCA)^[1] 已经被成功地应用到了人脸识别领域。它寻求一对线性变换, 使得两组向量集合分别投影到这两个线性子空间中, 从而使得投影后两组向量集合之间的相关性最大。如果两组向量集合分别是同一组人脸的两种不同角度的图像, 那么投影到相关性最大的子空间后可以有效提高识别率。

然而, CCA 与著名的 LDA^[2] 一样存在奇异问题。我们知道 LDA, CCA 所用的是总体协方差矩阵的求逆运算, 由于样本的向量表示位于一个高维的线性空间

中, 而样本的个数相对偏少, 使得协方差矩阵一般不满秩, 所以造成矩阵奇异而无法求出正确的广义特征值和特征向量。常见的解决方法是用 PCA^[3] 降维, 或是在总体的协方差矩阵上加上一个小的扰动因子等等, 但是这些方法常常会影响最终的识别率。

考虑到人脸图像的样本, 从本质上来讲是2阶张量, 如果在计算中保持它们的张量特性, 则不仅计算量会大大减少, 而且由于高维小样本产生的奇异性问题也将不再存在。基于这点考虑, Yang Jian 等人于2004年在 PCA 的基础上提出了 2DPCA 的方法^[4], 保持了样本的二阶张量特性, 不仅加快了运算速度, 减小了计算量, 而且识别率也高于一维时的情况, 但是这篇文章并

不能算是完全用了张量的概念,由于每个2阶张量的投影是需要左右两个投影矩阵的,而Yang Jian的2DPCA只寻找了一个投影矩阵进行了单边的投影。于是,Zhang Daoqiang等人于2005年提出了(2D)²PCA^[5],通过左右两个最佳投影矩阵使得样本矩阵进一步降维。当然,PCA的方法毕竟是非监督的方法,没有利用人脸数据的类内类间信息。于是,Ye Jieping等人在2005年对LDA进行了改进,得到了2DLDA并推导出了它的迭代算法^[6],算法收敛快且稳定,没有奇异问题。由此可见用样本的矩阵表示代替样本的向量表示来进行子空间学习,不仅能避免小样本造成的奇异性的问题,大大降低计算量,而且识别率还常常优于其对应的一维子空间学习的方法。于是本文的2D-DCCA也是采用将样本用其矩阵表示的方法来避免奇异性和减少计算量。

CCA的方法虽然增大了两个样本组之间的相关性,但是并没有像LDA那样利用类内与类间的信息,这使得原有样本的信息并没有被充分利用。于是判别典型相关分析(DCCA)也就相应产生^[7],不过这个一维的方法始终是存在奇异问题而影响了应有的高识别率,于是本文将2阶张量引入DCCA算法,在避免奇异问题,减小计算量的同时,并且用迭代的方法找出2阶张量的两对左右投影矩阵,使得算法自始至终保持了2阶张量的特性,得到了高识别率,并且试验结果同时表明,2D-DCCA的方法对人脸角度变化时的识别率很稳定。

本文以下的內容安排:在第2小节简要描述CCA的基本算法。第3小节的开头描述DCCA的原理及不足,然后详细阐述本文提出的2D-DCCA的原理,最后是2D-DCCA的迭代算法流程。在文章的第4,第5小节分别是实验结果的对比分析和结论。

2 典型相关分析(CCA)

CCA的方法源于研究两组随机向量之间的相关性的问题。假设一个形如 (\vec{x}, \vec{y}) 的多元随机向量,现有 N 对样本: $(\vec{x}_1, \vec{y}_1), \dots, (\vec{x}_N, \vec{y}_N)$ 。我们用 X 表示向量组 (x_1, \dots, x_N) ,并且同样地用 Y 表示向量组 (y_1, \dots, y_N) 。要寻求一对线性变换 \vec{w}_x, \vec{w}_y ,使得:

向量组 (x_1, \dots, x_N) 在 \vec{w}_x 上的投影为 $X \vec{w}_x$,向量组 (y_1, \dots, y_N) 在 \vec{w}_y 上的投影为 $Y \vec{w}_y$,并使得两组向量投影后的相关性最大,即:

$$\begin{aligned} \rho &= \max_{w_x, w_y} \text{corr}(Xw_x, Yw_y) \\ &= \max_{w_x, w_y} \frac{\langle Xw_x, Yw_y \rangle}{\|Xw_x\| \|Yw_y\|} \end{aligned} \quad (1)$$

其中,向量组 (x_1, \dots, x_N) 和 (y_1, \dots, y_N) 是零均值的。

于是对于以上方程的求解可转化为:

$$\begin{aligned} \rho &= \max_{w_x, w_y} \frac{\langle Xw_x, Yw_y \rangle}{\|Xw_x\| \|Yw_y\|} \\ &= \max_{w_x, w_y} \frac{\sum_{i=1}^N w_x^T x_i y_i^T w_y}{\sqrt{\sum_{i=1}^N w_x^T x_i x_i^T w_x} \sqrt{\sum_{i=1}^N w_y^T y_i y_i^T w_y}} \\ &= \max_{w_x, w_y} \frac{w_x^T C_{xy} w_y}{\sqrt{w_x^T C_{xx} w_x} \sqrt{w_y^T C_{yy} w_y}} \end{aligned} \quad (2)$$

其中,

$$\begin{aligned} C_{xy} &= \frac{1}{N} \sum_{i=1}^N x_i y_i^T, \quad C_{xx} = \frac{1}{N} \sum_{i=1}^N x_i x_i^T \\ C_{yy} &= \frac{1}{N} \sum_{i=1}^N y_i y_i^T, \quad C_{yx} = C_{xy}^T \end{aligned} \quad (3)$$

于是问题变成解方程的广义特征值与广义特征向量的问题:

$$\begin{pmatrix} 0 & C_{xy} \\ C_{yx} & 0 \end{pmatrix} \begin{pmatrix} w_x \\ w_y \end{pmatrix} = \lambda \begin{pmatrix} C_{xx} & 0 \\ 0 & C_{yy} \end{pmatrix} \begin{pmatrix} w_x \\ w_y \end{pmatrix} \quad (4)$$

其中, $\lambda = \lambda_x = \lambda_y$ 。求解得到的一组线性变换对 \vec{w}_x, \vec{w}_y 构成了 W_x, W_y 矩阵,这就是识别样本要投影到的线性子空间。

3 二维判别典型相关分析(2D-DCCA)

3.1 判别典型相关分析 DCCA

典型相关分析CCA固然能够使得向量组 X 和向量组 Y 之间的相关性最大,但是对于人脸识别系统来说,判别时并没有利用训练样本的类内类间信息,如果可以类似于LDA的方法去对人脸样本的类内和类间的信息加以利用,则可以更进一步增强CCA的人脸识别能力。于是Tinghai Sun等人提出了DCCA的方法^[7],对于CCA加以改进,使得类内差别最小的同时使得类间差别最大,所以我们的最优化的目标函数变成了:

$$\begin{aligned} \max_{w_x, w_y} (w_x^T C_w w_y - \eta \cdot w_x^T C_b w_y) \\ \text{s.t. } w_x^T X X^T w_x = 1, \quad w_y^T Y Y^T w_y = 1 \end{aligned} \quad (5)$$

这就是DCCA的方法。此方法仅需要求解 W_x, W_y 两个矩阵,可以一次解方程完成求解,但是这个方法存在奇异值问题,如果用PCA降维或是采用加入扰动因子的方法,则会使识别率下降。于是,采用二维DCCA的方法,不仅可以避免奇异值问题,使得识别率有所提升,而且具有运算快,存储空间小等优点。

3.2 二维判别典型相关分析 2D-DCCA

现在我们重新定义样本集合,设共有样本对 $(X_i,$

Y_i) N 个,分为 c 个类,每类有样本 n_i 个, $i=1, \dots, c$ 。可

知: $\sum_{i=1}^c n_i = N$ 。我们用 X 表示样本集合:

$$(X_1^{(1)}, \dots, X_{n_1}^{(1)}, \dots, X_1^{(i)}, \dots, X_{n_i}^{(i)}, X_1^{(c)}, \dots, X_{n_c}^{(c)})$$

其中 $X_j^{(i)}$, $j=1, \dots, n_i$ 为第 i 类的第 j 个样本的矩阵表示, 同样地,用 Y 表示样本集合:

$$(Y_1^{(1)}, \dots, Y_{n_1}^{(1)}, \dots, Y_1^{(i)}, \dots, Y_{n_i}^{(i)}, Y_1^{(c)}, \dots, Y_{n_c}^{(c)})$$

其中 $X_j^{(i)} \in \mathbf{R}^{m \times n}$, $Y_j^{(i)} \in \mathbf{R}^{m \times n}$, $j=1, \dots, n_i$, 并且 X 集合和 Y 集合中的样本矩阵均已化为零均值。

由于每个样本点由原来的向量表示变成了现在的矩阵表示,所以我们需要找出的不是一对线性变换 w_x, w_y ,而是两对线性变换 $(l_x, l_y), (r_x, r_y)$,使得样本集 X 和 Y 投影后: $l_x^T X r_x$ 和 $l_y^T Y r_y$ 的类内差别最小,类间差别最大,便于判别。

于是目标函数变为两个,目标函数一可以求解出 (l_x, l_y) :

$$\max_{w_x, w_y} (l_x^T C_w^R l_y - \eta \cdot l_x^T C_b^R l_y) \quad (6)$$

$$s.t. \quad l_x^T C_{xx}^R l_x = 1, \quad l_y^T C_{yy}^R l_y = 1$$

目标函数二可以求解出 (r_x, r_y) :

$$\max_{w_x, w_y} (r_x^T C_w^L r_y - \eta \cdot r_x^T C_b^L r_y) \quad (7)$$

$$s.t. \quad r_x^T C_{xx}^L r_x = 1, \quad r_y^T C_{yy}^L r_y = 1$$

其中的 C_w^R, C_w^L 和 C_b^R, C_b^L 矩阵是本文定义的类内相关矩阵和类间相关矩阵。

以目标函数一为例进行化简:

由于仅找出一对 (l_x, l_y) 线性变换,投影后是不能充分描述样本集合 X 和 Y 的,故需要找出一组这样的线性变换对 $(l_{x1}, l_{y1}), (l_{x2}, l_{y2}), \dots, (l_{xd1}, l_{yd1})$,于是用矩阵 L_x 表示 $[l_{x1} \quad l_{x2} \quad \dots \quad l_{xd1}]$,用矩阵 L_y 表示 $[l_{y1} \quad l_{y2} \quad \dots \quad l_{yd1}]$,同样的,用矩阵 R_x 表示 $[r_{x1} \quad r_{x2} \quad \dots \quad r_{xd2}]$ 和用矩阵 R_y 表示 $[r_{y1} \quad r_{y2} \quad \dots \quad r_{yd2}]$.可见, $L_x \in \mathbf{R}^{m \times d1}$, $L_y \in \mathbf{R}^{m \times d1}$, $R_x \in \mathbf{R}^{n \times d2}$, $R_y \in \mathbf{R}^{n \times d2}$.

C_w^R, C_b^R 分别定义如下:

$$C_w^R = \sum_{i=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_i} X_k^{(i)} R_x \cdot R_y^T Y_l^{(i)T} \quad (8)$$

$$\begin{aligned} C_b^R &= \sum_{i=1}^c \sum_{j=1}^{n_i} \sum_{k=1}^{n_j} \sum_{l=1}^{n_j} X_k^{(i)} R_x \cdot R_y^T Y_l^{(j)T} \\ &= \sum_{i=1}^c \sum_{j=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_j} X_k^{(i)} R_x \cdot R_y^T Y_l^{(j)T} - \sum_{i=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_i} X_k^{(i)} R_x \cdot R_y^T Y_l^{(i)T} \\ &= \mathbf{0} - C_w^R = -C_w^R \end{aligned} \quad (9)$$

因为 $X_j^{(i)} \in \mathbf{R}^{m \times n}$, $Y_j^{(i)} \in \mathbf{R}^{m \times n}$, $j=1, \dots, n_i$ 均是零均值的样本矩阵,所以上式 C_b^R 中:

$$\sum_{i=1}^c \sum_{j=1}^c \sum_{k=1}^{n_i} \sum_{l=1}^{n_j} X_k^{(i)} R_x R_y^T Y_l^{(j)T} = \mathbf{0} \quad (10)$$

又有定义:

$$C_{xx}^R = \sum_{i=1}^N X_i R_x \cdot R_x^T X_i^T \quad (11)$$

$$C_{yy}^R = \sum_{i=1}^N Y_i R_y \cdot R_y^T Y_i^T$$

于是目标函数一变成了:

$$\begin{aligned} &\max_{w_x, w_y} (l_x^T C_w^R l_y - \eta \cdot l_x^T C_b^R l_y) \\ &= \max_{w_x, w_y} (l_x^T C_w^R l_y + \eta \cdot l_x^T C_w^R l_y) \\ &= (1 + \eta) \max_{w_x, w_y} (l_x^T C_w^R l_y) \end{aligned} \quad (12)$$

其中 $(1 + \eta)$ 只是一个系数,不影响优化结果,所以我们的优化目标成为:

$$\max_{w_x, w_y} (l_x^T C_w^R l_y) \quad (13)$$

$$s.t. \quad l_x^T C_{xx}^R l_x = 1, \quad l_y^T C_{yy}^R l_y = 1 \quad (14)$$

$$\Rightarrow \begin{pmatrix} C_w^R \\ (C_w^R)^T \end{pmatrix} \begin{pmatrix} l_x \\ l_y \end{pmatrix} = \lambda \begin{pmatrix} C_{xx}^R & \\ & C_{yy}^R \end{pmatrix} \begin{pmatrix} l_x \\ l_y \end{pmatrix} \quad (15)$$

求解上述方程的广义特征向量可得出一组 $(l_{x1}, l_{y1}), \dots, (l_{xd1}, l_{yd1})$,于是这 $d1$ 对线性变换即为所求:

$$L_x = (l_{x1} \quad l_{x2} \quad \dots \quad l_{xd1}) \quad (16)$$

$$L_y = (l_{y1} \quad l_{y2} \quad \dots \quad l_{yd1})$$

同理,目标函数二成为:

$$\max_{w_x, w_y} (r_x^T C_w^L r_y) \quad (17)$$

$$s.t. \quad r_x^T C_{xx}^L r_x = 1, \quad r_y^T C_{yy}^L r_y = 1 \quad (18)$$

$$\Rightarrow \begin{pmatrix} C_w^L \\ (C_w^L)^T \end{pmatrix} \begin{pmatrix} r_x \\ r_y \end{pmatrix} = \lambda \begin{pmatrix} C_{xx}^L & \\ & C_{yy}^L \end{pmatrix} \begin{pmatrix} r_x \\ r_y \end{pmatrix} \quad (19)$$

求解广义特征向量得出一组 $(r_{x1}, r_{y1}), \dots, (r_{xd2}, r_{yd2})$,于是这 $d2$ 对线性变换即为所求:

$$R_x = (r_{x1} \quad r_{x2} \quad \dots \quad r_{xd2}) \quad (20)$$

$$R_y = (r_{y1} \quad r_{y2} \quad \dots \quad r_{yd2})$$

有了这2对投影矩阵,则可以把已经分成两组的测试样本分别经过左右投影变换投影到子空间中,然后用最近邻分类器进行分类。

3.3 2D-DCCA的算法流程

观察2D-DCCA的优化目标函数可知,求解 L_x, L_y 时需要已知 R_x, R_y ,同样的求解 R_x, R_y 时需要已知 L_x, L_y .这就说明 L_x, L_y, R_x, R_y 的求解方式是迭代的。

故此迭代算法流程如下:

(1) 输入样本矩阵 X, Y ,各有 N 个样本,含 c 类, $X_j^{(i)} \in \mathbf{R}^{m \times n}$, $Y_j^{(i)} \in \mathbf{R}^{m \times n}$, $j=1, \dots, n_i$,

(2) 初始化 R_x, R_y :

$$R_x = \begin{bmatrix} \mathbf{I}_{d2 \times d2} \\ \mathbf{0} \end{bmatrix}_{n \times d2} \quad (21)$$

$$R_y = \begin{bmatrix} \mathbf{I}_{d2 \times d2} \\ \mathbf{0} \end{bmatrix}_{n \times d2}$$

(3) 按照前文的定义式计算 $C_w^R, C_b^R, C_{xx}^R, C_{yy}^R$

(4) 按照

$$\begin{pmatrix} C_w^R \\ (C_w^R)^T \end{pmatrix} \begin{pmatrix} l_x \\ l_y \end{pmatrix} = \lambda \begin{pmatrix} C_{xx}^R \\ C_{yy}^R \end{pmatrix} \begin{pmatrix} l_x \\ l_y \end{pmatrix} \quad (22)$$

可求出 $d1$ 个广义特征向量作为 L_x, L_y

(5) 用上一步求出的 L_x, L_y 来计算 $C_w^L, C_b^L, C_{xx}^L, C_{yy}^L$

(6) 同理按照

$$\begin{pmatrix} C_w^L \\ (C_w^L)^T \end{pmatrix} \begin{pmatrix} r_x \\ r_y \end{pmatrix} = \lambda \begin{pmatrix} C_{xx}^L \\ C_{yy}^L \end{pmatrix} \begin{pmatrix} r_x \\ r_y \end{pmatrix} \quad (23)$$

可求出 $d2$ 个广义特征向量作为 R_x, R_y

(7) 回到(3)进行下一轮的迭代计算直到 L_x, L_y 和 R_x, R_y 收敛。

在本算法中,虽然 L_x, L_y, R_x, R_y 的求解方式是迭代的,但是由于它们在循环中收敛特别快,所以迭代次数不超过 10 就可以达到最佳识别率,因此对全算法的计算复杂度几乎没有增加,并且由于算法中所用的是样本矩阵,而非样本向量,所以在协方差矩阵的求解和分解部分,计算速度大大提高。因此总的计算复杂度较之其一为版本有很大下降。

4 实验结果分析

4.1 对 2D-DCCA 算法性能的分析

本文分别以 AR, CUM-PIE 数据库为基础进行实验。实验共分两部分,实验一是验证引入二阶张量概念的 2D-DCCA 识别率较之其一维版本,能够达到良好的识别率。实验二是验证 2D-DCCA 对于人脸不同角度进行识别时具有稳定的识别率。

首先,先对 2D-DCCA 进行其自身性能的分析。在本算法中,2D-DCCA 有一个参数,就是迭代次数。由于此方法收敛很快,所以迭代次数可以自行设定,收敛到最

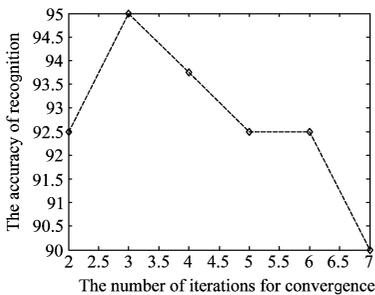


图1 2D-DCCA 的识别率与迭代次数的关系

佳子空间的迭代次数不超过 10 次,这点可以从图 1 中看出。图 1 所示的是实验 1 中的迭代次数从 2 次到 7 次的识别率,可以看出本组数据只需要 3 次就可以收敛到最佳子空间 L, R ,如果迭代次数超过 3 次,则会出现“过学习”的情况,使得识别率反而下降。

4.2 实验 1:2D-DCCA 与 CCA, DCCA 的识别性能比较

我们从 AR 人脸库中随机选择 80 人,任取 40 人做训练,余下的 40 人做测试。每次实验每人取 1 张无表情正面像做 $\{X_i\}$ 样本集合,从其余的几张不同表情样本中任取一张做 $\{Y_i\}$ 样本集合。本实验分三组进行,如图 2 所示。每张图像的大小为 50×50 像素点,并且两个样本集合各自为零均值,各图像以双眼为参考点对齐。最后使用 1-NN 分类器进行判决。

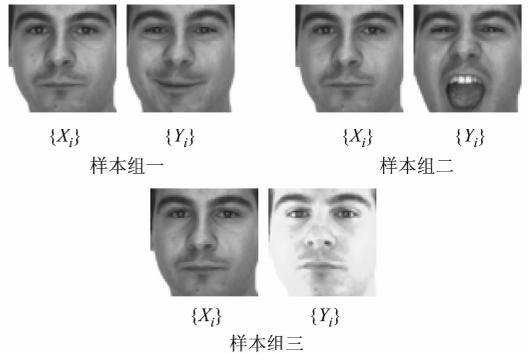


图2 实验 1 所用的三组实验样本

表格 1 几种关于典型相关分析的算法的性能比较

算法 \ 样本组	CCA	DCCA	2D-DCCA
样本组一	90%	90%	95%
样本组二	57.5%	60%	62.5%
样本组三	85%	82.5%	97.5%

这个实验主要用于说明,将样本数据用 2 阶张量来表示,能使 2D-DCCA 算法在 3 方面占据性能的优势:第一,识别率高于其一维版本的识别率。第二,存储空间大大减少,并且避免了奇异问题。第三,训练和识别时间总共大约在 3 到 5 秒,而 CCA 和 DCCA 的训练和识别时间在 5 分钟左右,本文中所有实验的运行环境是 Intel 酷睿二代双核 CPU,主频 2.66GHZ,2GB 内存。

4.3 实验 2:2D-DCCA 对不同角度下人脸图像识别具有稳定性

本文提出的方法主要优点在于,对于不同角度下的人脸识别率很稳定,不会像其他传统方法那样,随着人脸角度的变化识别率严重下降。这一点从实验中也可以看出。我们采用 CMU-PIE 人脸库,从这个人脸库中选用 62 人,任取 31 人做训练,余下的 31 人做测试,每张人脸大小为 50×50 像素点,取每个人的第 27 张正

脸作为参考集合,即 $\{X_i\}$ 样本集合,分别取每个人的第05,29,37,11张作为四个对应子集,即 $\{Y_i\}_1, \{Y_i\}_2, \{Y_i\}_3, \{Y_i\}_4$ 样本集合,分别进行四次实验。

本文将提出的2D-DCCA的方法与2DPCA, 2DLDA和LLR-step5withPCA+LDA的方法进行比较,其中最后

一种方法是Chai Xiujuan等人于2007年在TIP上发表的局部线性回归的方法^[8],针对人脸不同姿态角度进行识别,由于与本文的实验所用数据库一样,均是针对人脸不同角度进行识别的,而且实验设计也相同,故直接取其实验结果进行比较。

表格2 在人脸角度的变化下几种识别算法的性能比较

识别率	P29 左22.5°	P05 右22.5°	P11 左45°	P37 右45°	平均识别率
2D-PCA	88.71%	98.39%	38.71%	19.35%	61.29%
2D-LDA	90.32%	95.16%	37.1%	77.42%	75%
2D-DCCA	100%	100%	93.55%	96.77%	98%
LLR-step5 with PCA+LDA	100%	98.5%	89.7%	82.4%	93%

从表格2可以看出,2DPCA, 2DLDA这些经典的方法直接用于人脸角度的识别是不合适的,这两种方法在人脸角度为 $\pm 22.5^\circ$ 时识别率略有下降,但是在人脸角度为 $\pm 45^\circ$ 时,识别率均不到50%。LLR-step5withPCA+LDA的方法采用了对人脸分割成很多小块,从而加强了两组图像之间的局部线性关系,所以对于人脸角度变化的识别率比较稳定,但是此方法也有不足之出,由于它的分块非常多,所以计算量较大。而本文提出的2D-DCCA的方法,不仅计算量小,耗时短,而且对于人脸角度的变化不敏感,具有稳定的识别率。

5 结论

本文将2阶张量的概念用于DCCA后,不仅使得运算量减小,节约了存储空间,而且避免了奇异问题使得识别结果得到了应有的提高,尤其对于人脸不同角度的识别表现出了十分稳定的性能。但是本文的方法也存在待改进之处,第一,人脸的变化角度达到90度时,识别率不到50%,这说明2D-DCCA这种统计的方法仍然不能从根本上解决人脸图像结构变化对识别率的影响。第二,本文的实验仅使用了一个参考图像作为 $\{X_i\}$ 样本集合和一个检测图像作为 $\{Y_i\}$ 样本集合,而如果被检测的人脸图像不止一个角度,则参考样本的个数应随之增加,所以可以尝试将人脸的各个角度放入一个高阶张量之中以推广2D-DCCA并提高识别率。

参考文献

- [1] H. Hotelling, "Relations between two sets of variates," *Biometrika*, vol. 28, pp. 312-377, 1936.
- [2] P. N. Belhumeur, J. P. Hespanha, and D. J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 711-720, July 1997.
- [3] M. Turk and A. Pentland, "Eigenfaces for Recognition",

J. Cognitive Neuroscience, vol. 3, no. 1, pp. 71-86, 1991.

- [4] J. Yang, D. Zhang, A. F. Frangi, and J. Y. Yang, "Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 26, no. 1, pp. 131-137, Jan, 2004.
- [5] D. Zhang, and Z. -H Zhou, "(2D)²PCA: Two-directional two-dimensional PCA for efficient face representation and recognition," *Neurocomputing*, Vol. 69, pp. 224-231, Dec, 2005.
- [6] J. Ye, R. Janardan and Q. Li, "Two-Dimensional Linear Discriminant Analysis," *NIPS*, 2004.
- [7] T. Sun, S. Chen, J. Yang, and P. Shi, "A Novel Method of Combined Feature Extraction for Recognition" 2008 Eighth IEEE International Conference on Data Mining, pp. 1043 -1048, Dec. 2008.
- [8] X. Chai, S. Shan, X. Chen, and W. Gao, "Locally Linear Regression for Pose-Invariant Face Recognition," *IEEE Trans. on Image Processing*, vol. 16, no. 7, pp. 1716-1725, 2007.

作者简介



黄丽坤(1985-),女,2003年到2007年于电子科技大学电子工程学院攻读学士学位,2007年至今在电子科技大学攻读信号与信息处理硕士学位。主要研究方向为人脸识别。

E-mail:yhcyhkk204@163.com



皮亦鸣,电子科技大学电子工程学院教授,博士生导师,现任电子科技大学电子工程学院副院长。主要研究方向为雷达信号处理、图像传输与处理和导航定位新技术等。E-mail:ympi@uestc.edu.cn