

文章编号:1001-9081(2008)09-2430-04

二维典型相关分析及其在人脸识别中的应用

宋东兴¹, 刘永俊¹, 陈才扣²

(1. 常熟理工学院 软件工程系, 江苏 常熟 215500; 2. 扬州大学 信息工程学院, 江苏 扬州 225009)
(sdxing@cslg.cn)

摘要:通过对传统的基于向量的典型相关分析(CCA)方法进行改进,提出了一种新的直接基于特征矩阵的二维典型相关分析方法(2DCCA),并将其应用于人脸识别的特征融合过程中。较基于向量的典型相关分析,该方法的优点主要有两点:第一,该方法计算过程中构造的协方差矩阵维数大幅度减小,这在一定程度上避免了人脸识别中存在的“高维小样本问题”;第二,由于协方差矩阵维数的缩减,使特征抽取的速度明显提高。最后在 ORL 标准人脸库和 AR 大型人脸数据库上的实验结果有效地验证了这两点。

关键词:典型相关分析;二维典型相关分析;特征融合;人脸识别

中图分类号: TP391.41 文献标志码:A

Two-dimensional canonical correlation analysis and its application to face recognition

SONG Dong-xing¹, LIU Yong-jun¹, CHEN Cai-kou²

(1. Department of Software Engineering, Changshu Institute of Technology, Changshu Jiangsu 215500, China;
2. College of Information Engineering, Yangzhou University, Yangzhou Jiangsu 225009, China)

Abstract: According to the traditional Canonical Correlation Analysis (CCA), a novel method of combined feature extraction called Two-Dimensional Canonical Correlation Analysis (2DCCA) was proposed in this paper. It combines feature matrix directly by using the main idea of image projection in face recognition. Compared with the traditional CCA based on feature vectors, this method has the following two main advantages: first, the Small Sample Size problem (SSS) occurred in traditional CCA is essentially inevitable as a result of the evidently reducing dimension of the covariance matrix. By the same reason, the second advantage is that much computational time would be saved if using the proposed method. Finally, extensive experiments performed on ORL and AR face database verify the effectiveness of the proposed method.

Key words: Canonical Correlation Analysis (CCA); Two-Dimensional Canonical Correlation Analysis (2DCCA); combined feature extraction; face recognition

0 引言

能否对样本进行有效的特征抽取是模式识别中的关键问题之一,近年来,基于各种单一准则的特征抽取算法层出不穷,特别以主分量分析和线性鉴别分析为代表的算法都有了长足的发展^[1-5]。与此同时,信息融合技术已成为一种新兴的数据处理方法,特别以多分类器组合为代表的决策级融合技术已成为目前模式识别领域的研究热点,在手写体汉字识别以及人脸识别中得到了较为成功地应用^[6-7]。

由于不同准则下对同一模式抽取的不同的特征向量总是反映了模式的不同特性,所以对它们的优化组合,对抽取更加有效的鉴别特征具有重要的意义。关于特征级融合方法的研究,虽然起步较晚,但目前已初见端倪^[8]。传统的特征级融合方法主要有串行特征融合和并行特征融合^[8]两种。最近,文献[9-11]提出了一种基于典型相关分析的特征融合方法,该方法首先抽取同一模式的两组特征向量,然后通过描述特征向量间相关性的判别准则函数,抽取这两组特征向量新的典型相关特征,用于分类识别。

虽然这种基于特征向量的典型相关分析方法为特征融合提供了一种有效的思路,但该方法的缺点也是显然的。由于该准则函数只能对一维的特征向量进行融合,所以当特征向量的维数较高时计算量会大幅度增加,而且此时在处理诸如人脸这样的高维小样本问题时,极易出现因协方差矩阵奇异而无法直接求解的困难。本文通过对传统的相关性判别函数修正,提出了直接基于特征矩阵的典型相关分析方法。该方法不仅能够对一维的特征向量进行特征融合,而且能够直接对二维特征矩阵进行特征融合,从而避免了特征向量维数过高的问题。可以证明,该方法是传统的典型相关分析的一种扩展。最后在 ORL 和 AR 人脸数据库上的实验证明了本文方法的有效性。

1 基于传统典型相关分析的特征融合

传统的典型相关分析最初是用于分析两组变量之间是否存在相关关系的。对于两个中心化后的随机向量 $x \in R^p$ 与 $y \in R^q$, 典型相关分析的目的是找到一对主轴投影方向 a_1 和 b_1 (称之为典型相关投影轴), 并用它们构造典型成分 $f_1 =$

收稿日期:2008-03-19;修回日期:2008-05-29。 基金项目:江苏省高校自然科学基金资助项目(05KJB520152)。

作者简介:宋东兴(1973-),男,江苏高邮人,讲师,硕士,主要研究方向:计算机网络、图像处理、软件工程; 刘永俊(1981-),男,山东青岛人,硕士,主要研究方向:人工智能与智能系统、模式识别、人脸识别; 陈才扣(1967-),男,江苏泰州人,副教授,博士,主要研究方向:模式识别、生物特征识别。

$\mathbf{a}_1^T \mathbf{x}, \mathbf{g}_1 = \mathbf{b}_1^T \mathbf{y}$,使得 f_1, g_1 的相关度达到最大,称 f_1, g_1 为第一对典型相关特征,继而再依次找到第二对主轴方向 $\mathbf{a}_2, \mathbf{b}_2$,求得典型相关特征 f_2, g_2 ,一直到第 d 对主轴方向 $\mathbf{a}_d, \mathbf{b}_d$ 和典型相关特征 f_d, g_d 为止。其中 f_i 与 g_i ($i = 1, \dots, d$)具有最大的相关性,而 f_i 与 f_j 以及 g_i 与 g_j ($i \neq j; i, j = 1, \dots, d$)则是不相关的。这样, x 与 y 之间的相关分析,只需要通过分析少数几对典型变量的关系即可达到目的。

要得到主轴 \mathbf{a}, \mathbf{b} 一般可通过采用 f, g 相关系数最大化的准则函数:

$$\begin{aligned} \max_r(f, g) &= \frac{\text{Cov}(f, g)}{\sqrt{\text{Var}(f) \text{Var}(g)}} = \\ &= \frac{E[\mathbf{a}^T \mathbf{x} \mathbf{y}^T \mathbf{b}]}{\sqrt{E[\mathbf{a}^T \mathbf{x} \mathbf{x}^T \mathbf{a}] E[\mathbf{b}^T \mathbf{y} \mathbf{y}^T \mathbf{b}]}} = \\ &= \frac{\mathbf{a}^T S_{xy} \mathbf{b}}{\sqrt{\mathbf{a}^T S_{xx} \mathbf{a}} \sqrt{\mathbf{b}^T S_{yy} \mathbf{b}}} \end{aligned} \quad (1)$$

其中: S_{xx}, S_{yy} 分别表示 x, y 的协方差矩阵, S_{xy} 表示它们之间的互协方差矩阵。

文献[9~11]将典型相关分析的理论应用于模式识别的特征融合过程中,提出了一种新的特征级融合方法。其基本思想简述如下:

设 $\omega_1, \omega_2, \dots, \omega_c$ 为 c 个模式类,模式样本 ξ_i ($i = 1, \dots, N$)为 n 维实向量,训练样本空间 $\Omega = \{\xi \mid \xi \in R^n\}$,设 x, y 分别为对同一模式 ξ 抽取的两组特征向量。该方法就是根据以上所述CCA的基本思想对这样的两组特征向量进行融合的。定义准则函数:

$$J(\boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{\boldsymbol{\alpha}^T S_{xy} \boldsymbol{\beta}}{(\boldsymbol{\alpha}^T S_{xx} \boldsymbol{\alpha} \cdot \boldsymbol{\beta}^T S_{yy} \boldsymbol{\beta})^{\frac{1}{2}}} \quad (2)$$

相应地, S_{xx}, S_{yy} 分别表示训练样本两种特征向量的协方差矩阵, S_{xy} 表示两种特征向量的互协方差矩阵($S_{xy} = S_{yx}^T$)。为了确保解的唯一性,令 $\boldsymbol{\alpha}^T S_{xx} \boldsymbol{\alpha} = \boldsymbol{\beta}^T S_{yy} \boldsymbol{\beta} = 1$,在此约束条件下求使式(2)达到最大值的典型投影轴 $\boldsymbol{\alpha}, \boldsymbol{\beta}$,用于抽取新的两组典型相关特征。

利用Lagrange乘子法^[12~13],可以将问题转化为求解如下两个广义本征方程的问题:

$$\begin{cases} S_{xy} \boldsymbol{\beta} - \lambda S_{xx} \boldsymbol{\alpha} = 0 \\ S_{yx} \boldsymbol{\alpha} - \lambda S_{yy} \boldsymbol{\beta} = 0 \end{cases} \quad (3)$$

如果 S_{xx}, S_{yy} 均为正定阵(非奇异)可由式(3)推得下式:

$$\begin{cases} S_{xy} S_{yy}^{-1} S_{yx} \boldsymbol{\alpha} = \lambda^2 S_{xx} \boldsymbol{\alpha} \\ S_{yx} S_{xx}^{-1} S_{xy} \boldsymbol{\beta} = \lambda^2 S_{yy} \boldsymbol{\beta} \end{cases} \quad (4)$$

具体求解过程详见参考文献[9~11]。

但是,由式(4)以及协方差矩阵 S_{xx}, S_{yy} 的构造不难发现,当特征向量 x, y 的维数较大以及训练样本数较少(高维小样本问题)时,该方法必然面临因 S_{xx}, S_{yy} 奇异而无法直接求解最优典型投影轴 $\boldsymbol{\alpha}, \boldsymbol{\beta}$ 的困难,这很大程度上限制了 x, y 中所能取的有效鉴别特征数。虽然文献[10]利用子空间方法提出了一种改进方案,但是其算法的复杂程度也是显而易见的。

2 基于2DCCA的特征融合及人脸识别

2.1 基本思想

二维图像投影理论^[5]在模式识别领域提供了一种快速有效的特征抽取方法。为此本文思考的角度是既然传统的

CCA在特征向量维数较高时存在制约性,那么能否采用二维投影理论将高维的特征向量 x, y 转化为特征矩阵 X, Y ($X_i, Y_i, i = 1, \dots, N$,表示由第*i*幅训练样本图像抽取的两种特征矩阵),然后用CCA来求得新的典型投影轴 $\boldsymbol{\alpha}^*, \boldsymbol{\beta}^*$,进而得到具有最大相关度的特征矩阵 F, G ($F = X\boldsymbol{\alpha}^*, G = Y\boldsymbol{\beta}^*$),用于分类识别。

但是从式(1)中不难看出,此时 f, g 均为标量,而如果将 x, y 转化为特征矩阵投影后的 F, G 将变为向量形式,这时直接采用原始的相关准则函数将无法直接求解。为此首先给出向量的相关系数定义如下。

定义1 m 维列向量 F, G 的相关系数为:

$$\rho(F, G) = \frac{\text{Cov}(F, G)}{\sqrt{\text{Cov}(F, F) \text{Cov}(G, G)}} \quad (5)$$

其中:

$$\begin{aligned} \text{Cov}(F, G) &= E(F_i - E(F_i))^T (G_i - E(G_i)) = \\ &= E[X_i \boldsymbol{\alpha}^* - E(X_i \boldsymbol{\alpha}^*)]^T [Y_i \boldsymbol{\beta}^* - E(Y_i \boldsymbol{\beta}^*)] = \\ &= \boldsymbol{\alpha}^{*T} E(X_i - E(X_i))^T (Y_i - E(Y_i)) \boldsymbol{\beta}^* \end{aligned} \quad (6)$$

$$\begin{aligned} \text{Cov}(F, F) &= E(F_i - E(F_i))^T (F_i - E(F_i)) = \\ &= E[X_i \boldsymbol{\alpha}^* - E(X_i \boldsymbol{\alpha}^*)]^T [X_i \boldsymbol{\alpha}^* - E(X_i \boldsymbol{\alpha}^*)] = \\ &= \boldsymbol{\alpha}^{*T} E(X_i - E(X_i))^T (X_i - E(X_i)) \boldsymbol{\alpha}^* \end{aligned} \quad (7)$$

$$\begin{aligned} \text{Cov}(G, G) &= E(G_i - E(G_i))^T (G_i - E(G_i)) = \\ &= E[Y_i \boldsymbol{\beta}^* - E(Y_i \boldsymbol{\beta}^*)]^T [Y_i \boldsymbol{\beta}^* - E(Y_i \boldsymbol{\beta}^*)] = \\ &= \boldsymbol{\beta}^{*T} E(Y_i - E(Y_i))^T (Y_i - E(Y_i)) \boldsymbol{\beta}^* \end{aligned} \quad (8)$$

定义2 由式(6~8),定义新的互协方差矩阵 $\bar{S}_{xy} = E(X_i - E(X_i))^T (Y_i - E(Y_i)), i = 1, \dots, N$;新协方差矩阵 $\bar{S}_{xx} = E(X_i - E(X_i))^T (X_i - E(X_i)); \bar{S}_{yy} = E(Y_i - E(Y_i))^T (Y_i - E(Y_i))$ 。

根据以上定义,可以自然地将式(2)传统的CCA准则函数推广为如下的二维典型相关分析准则函数,使得投影特征向量 F, G 的相关系数最大。

$$\begin{aligned} \max_J(\boldsymbol{\alpha}^*, \boldsymbol{\beta}^*) &= \frac{\boldsymbol{\alpha}^{*T} \bar{S}_{xy} \boldsymbol{\beta}^*}{(\boldsymbol{\alpha}^{*T} \bar{S}_{xx} \boldsymbol{\alpha}^* \cdot \boldsymbol{\beta}^{*T} \bar{S}_{yy} \boldsymbol{\beta}^*)^{\frac{1}{2}}} \\ \text{s.t. } \boldsymbol{\alpha}^{*T} \bar{S}_{xx} \boldsymbol{\alpha}^* &= \boldsymbol{\beta}^{*T} \bar{S}_{yy} \boldsymbol{\beta}^* = 1 \end{aligned} \quad (9)$$

设特征矩阵 X, Y 的维数分别为 $m \times k_1, m \times k_2$,则 \bar{S}_{xy} 的维数为 $k_1 \times k_2$, $\bar{S}_{xx}, \bar{S}_{yy}$ 分别为 $k_1 \times k_1, k_2 \times k_2$;而在传统的CCA中 S_{xy}, S_{xx}, S_{yy} 的维数分别为 $(m \times k_1) \times (m \times k_2), (m \times k_1) \times (m \times k_1), (m \times k_2) \times (m \times k_2)$ 。可以发现其维数大幅度的缩减,这一方面在理论上提高了特征分解计算的速度,另一方面也为保证 $\bar{S}_{xx}, \bar{S}_{yy}$ 的正定性提供了理论基础。实验证明,一般情况下,在训练样本总数不少于2时,该方法均能达到 $\bar{S}_{xx}, \bar{S}_{yy}$ 正定,而这一条件在模式识别的现实问题中一般都可以保证。

2.2 二维最大散度差鉴别分析及人脸识别特征抽取

人脸识别过程中能否有效的抽取人脸图像的有效鉴别特征是提高正确识别率的关键问题之一,最近陈才扣等将最大散度差鉴别分析方法^[4]推广到二维图像空间中,提出了一种二维最大散度差鉴别分析方法^[5]用来有效地抽取图像的特征矩阵。本文将采用该方法所抽取的特征验证基于二维CCA特征融合方法的有效性。现将特征抽取的具体过程简述如下:

设 $\omega_1, \omega_2, \dots, \omega_c$ 为 c 个模式类, 第 i 类训练样本数为 N_i , 训练样本总数为 N 。第 i 类的第 j 个训练样本图像为 $m \times n$ 的矩阵 A_i^j ($i = 1, 2, \dots, c; j = 1, 2, \dots, N_i$)。第 i 类的训练样本的平均图像为 $\bar{A}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} A_i^j$, 所有训练样本的均值图像记作 $\bar{A} = \frac{1}{c} \sum_{i=1}^c \bar{A}_i$ 。

设 w 表示一个 n 维列向量, 称之为投影轴。训练样本图像矩阵 A_i^j 投影到 w 上后, 得到如下的投影特征向量:

$$Q_i^j = A_i^j w; \quad i = 1, 2, \dots, c; j = 1, 2, \dots, N_i \quad (10)$$

假设第 i 类投影特征向量的均值为 \bar{Q}_i , 所有训练样本投影特征向量的均值为 \bar{Q} , 则 $\bar{Q}_i = \bar{A}_i w, \bar{Q} = \bar{A} w$ 。假设 P_i 表示第 i 类的先验概率 ($i = 1, 2, \dots, c$), 构造各类训练样本在投影轴上投影后所得特征向量的类间散布矩阵 MB 和类内散布矩阵 MW 如下:

$$\begin{aligned} MB &= \sum_{i=1}^c P_i (\bar{Q}_i - \bar{Q})(\bar{Q}_i - \bar{Q})^T = \\ &\sum_{i=1}^c P_i [(\bar{A}_i - \bar{A})w] [(\bar{A}_i - \bar{A})w]^T \end{aligned} \quad (11)$$

$$MW = \sum_{i=1}^c P_i \frac{1}{N_i} \sum_{j=1}^{N_i} [(A_i^j - \bar{A}_i)w] [(A_i^j - \bar{A}_i)w]^T \quad (12)$$

二维图像投影理论的基本思想就是寻找最优投影轴 w , 使投影特征向量的类间离散度 $tr(MB)$ 达到最大的同时, 而类内离散度 $tr(MW)$ 达到最小。由式(11~12)不难推出 $tr(MB), tr(MW)$ 分别为如下形式:

$$tr(MB) = w^T \left[\sum_{i=1}^c P(\omega_i) (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \right] w \quad (13)$$

$$tr(MW) = w^T \left[\sum_{i=1}^c P(\omega_i) \frac{1}{N_i} \sum_{j=1}^{N_i} (A_i^j - \bar{A}_i)^T (A_i^j - \bar{A}_i) \right] w \quad (14)$$

定义图像类间散布矩阵 M_b 和图像类内散布矩阵 M_w 如下:

$$M_b = \sum_{i=1}^c P_i (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \quad (15)$$

$$M_w = \sum_{i=1}^c P_i \frac{1}{N_i} \sum_{j=1}^{N_i} (A_i^j - \bar{A}_i)^T (A_i^j - \bar{A}_i) \quad (16)$$

易证明 M_b 和 M_w 均为 $n \times n$ 非负定矩阵。为寻找最优投影轴 w , 定义如下二维最大散度差鉴别准则函数:

$$J_s(w) = tr(MB) - tr(MW) = w^T M_b w - w^T M_w w = w^T (M_b - M_w) w \quad (17)$$

使准则函数达到极值的向量 w 就是最优投影轴, 进一步讲, 对散度差矩阵 $(M_b - M_w)$ 进行特征分解得到的最大的本征值对应的本征向量就是所要求的最优投影轴。

一般情况下, 特征抽取时只选一个最优投影轴是不够的, 设所得最优投影轴 w_1, w_2, \dots, w_d 为特征分解时前 d 个最大特征值对应的特征向量。将 $m \times n$ 图像矩阵 A_i^j 往投影轴 w 上投影可得该图像的第一个 $m \times d$ 的特征矩阵 $Q_i^j = A_i^j w$ 。

同样, 如果将每个图像矩阵进行转置作为训练样本 $B_i^j = A_i^{jT}$ 然后投影, 则可以得到另一组最优投影轴 $w_1^*, w_2^*, \dots, w_d^*$, 将 $n \times m$ 的矩阵 B_i^j 往 w^* 上投影, 又可以得到该样本图像的另一个 $n \times d$ 的特征矩阵 $O_i^j = B_i^j w^* = A_i^{jT} w^*$ 。根据文献[5]

的分析, Q_i^j, O_i^j 分别相当于按原始图像矩阵各行和各列向量进行的鉴别特征抽取。

2.3 特征融合与识别步骤

1) 用 2.2 节所述方法求得投影轴 w, w^* 抽取各训练样本的两个特征矩阵 Q_i^j, O_i^j , 并令 $X_i^j = Q_i^{jT}, Y_i^j = O_i^{jT}$, 作为后面特征融合输入的特征矩阵。

2) 根据定义 2 分别计算 $\bar{S}_{XY}, \bar{S}_{XX}, \bar{S}_{YY}$ 。

3) 由式(4), 定义 $M_{XY} = \bar{S}_{XX}^{-1} \bar{S}_{XY} \bar{S}_{YY}^{-1} \bar{S}_{YX}, M_{YX} = \bar{S}_{YY}^{-1} \bar{S}_{YX}$, 分别对其进行特征分解, 取前 d 对作为典型相关投影轴 α_i^*, β_i^* ($i = 1, \dots, d$)。

4) 将模式样本特征矩阵 X, Y 分别往典型相关投影轴 α^*, β^* 上投影, 得到新的典型相关特征矩阵 $X^* = X\alpha^*, Y^* = Y\beta^*$ 。

5) 将训练样本和测试样本的典型相关特征矩阵 X^*, Y^* 输入到分类器进行比对, 给出测试样本所属的类别。

3 实验结果与分析

3.1 实验一

ORL 标准人脸库由 40 人, 每人 10 幅 112×92 的图像组成, 其中有些图像是拍摄于不同时期的; 人的脸部表情和脸部细节有着不同程度的变化, 比如, 笑或不笑, 眼睛或睁或闭, 戴或不戴眼镜; 人脸姿态也有相当程度的变化, 深度旋转和平面旋转可达 20° ; 人脸的尺度也有多达 10% 的变化。图 1 是 ORL 人脸库中某一人 10 幅图像。




图 1 ORL 人脸图像数据库中的图像

表 1 2DMSLDA 在两种分类器下正确识别率 %

投影轴数	2DMSLDA 行		2DMSLDA 列	
	MD	1NN	MD	1NN
1	72.250	81.75	50.500	67.00
2	78.000	88.50	66.125	75.50
3	82.025	90.25	75.250	87.00
4	83.500	91.00	81.025	90.50
5	85.250	91.25	83.000	91.00
6	84.250	91.00	82.175	91.00
7	85.000	91.50	84.000	89.50
8	85.175	91.00	84.000	89.50
9	85.250	91.50	85.250	89.00
10	85.500	91.50	84.125	91.00

本实验中, 为测试算法对不同样本的鲁棒性, 在每人的图像中随机选择其中五幅图像作为训练样本, 剩余五幅作为测试样本, 这样训练样本和测试样本总数均为 200。表 1 为分别采用二维最大散度差鉴别分析方法按行(2DMSLDA 行)、按列(2DMSLDA 列)进行特征抽取, 采用最小距离(MD)和最近邻(1NN)分类器进行分类识别结果。表 2 为将两种特征矩阵分别采用传统的 CCA(首先将各特征矩阵拉伸成特征向量的形式)和二维典型相关分析直接进行特征融合, 然后进行识别效果的比较。每种方法运行 20 次, 统计其平均正确识别率进行比较。(所用机器: Pentium 4 CPU 2.80 GHz, 256 MB)

内存)

表2 采用CCA和2DCCA后的正确识别率 %

投影轴数	传统CCA		2DCCA	
	MD	1NN	MD	1NN
1	63.025	75.175	81.175	90.000
2	68.500	83.250	85.250	92.250
3	80.175	90.000	87.025	93.000
4	82.175	91.250	86.025	94.250
5	84.000	91.025	87.175	95.500
6	84.025	91.175	87.500	95.025
7	85.025	92.500	88.250	95.500
8	86.025	92.175	88.175	95.000
9	87.500	92.025	88.125	95.175
10	86.250	92.175	88.175	95.500

注:原始特征抽取时取的投影轴数为5。

表3 采用CCA和2DCCA的抽取及识别时间对照 s

特征融合方法	特征抽取及融合的时间	分类识别时间	总时间
传统CCA	54.375	0.584	54.959
2DCCA	8.061	0.832	8.893

该实验Step1中 w 取为前5个投影轴,进行投影得到的 $\mathbf{Q}_i^j, \mathbf{O}_i^j$ 维数分别为 112×5 和 92×5 相应的特征矩阵 $\mathbf{X}_i^j, \mathbf{Y}_i^j$ 为 5×112 和 5×92 。从表2的数据可以发现,在传统的CCA方法中,正如前所述由于协方差矩阵的维数较高造成 $\bar{\mathbf{S}}_{xx}, \bar{\mathbf{S}}_{yy}$ 具有奇异性,因此当采用“扰动法”使其变为非奇异时,正确识别率大幅度下降,甚至达不到表1中原始单特征矩阵时的效果。而2DCCA中由于协方差矩阵的维数大幅度降低,所以避免了这一困难,识别率有了明显的提高。表3的实验数据验证了本文算法的快速性。

3.2 实验二

为验证本文算法的有效性,实验还在一个规模较大的AR人脸图像数据库上进行。它由120人,每人26张在不同时期、光照、姿态、表情、遮挡等条件下拍摄的人脸图像组成。这26张图像拍摄于两个时期,前13张图像为一个时期,后13张图像为另一个时期,前后相差14天。本实验仅考查无遮挡的情况,采用1~7张作为训练样本,14~20张作为测试样本。采用分辨率为 50×40 的规范化人脸图像,并进行了灰度处理。图2为其中某人经过规范化的图像。




图2 AR人脸库中某人经过灰度均衡化处理后的规范化人脸图像

本实验首先采用2DMSLDA方法取5个投影轴对原始图像矩阵进行特征抽取,这样得到的特征矩阵 $\mathbf{X}_i^j, \mathbf{Y}_i^j$ 的维数为 5×50 和 5×40 。此时采用传统的CCA特征融合方法每类取7个训练样本,协方差矩阵 $\bar{\mathbf{S}}_{xx}, \bar{\mathbf{S}}_{yy}$ 一般也是非奇异的。本实验的目的就是在该情况下验证本文方法的有效性。

该实验再次证实了本文方法的有效性。另外也说明本文方法对于时间、光照、姿态、表情等变化具有较好的鲁棒性。

4 结语

本文在传统的典型相关分析的基础上对原始相关性准则

函数修正,成功地引入二维图像投影理论,提出了二维典型相关分析方法(2DCCA)。该方法通过直接对特征矩阵进行融合,较传统的基于向量的典型相关分析融合方法不仅大幅度的提高了特征抽取的速度,而且有效地避免了处理高维小样本问题时存在的因协方差矩阵奇异而无法直接求解的困难。最后在ORL、AR标准人脸库中验证了本文算法的有效性,实验数据表明,由于二维图像投影理论本身有效地保持了图像的结构特征,所以该方法的正确识别率较原始方法也有明显的提高。

表4 采用CCA和2DCCA特征融合后的正确识别率 %

投影轴数	传统CCA		2DCCA	
	MD	1NN	MD	1NN
6	46.19	68.57	78.81	92.38
7	52.38	71.43	81.19	93.33
8	56.19	73.57	81.67	93.81
9	57.86	78.81	83.10	94.29
10	60.00	79.52	83.10	94.52
11	61.43	82.62	83.33	94.52
12	63.10	85.00	83.81	94.76
13	65.48	86.43	84.29	95.00
14	66.90	87.38	85.27	95.24
15	67.86	88.81	85.95	95.24

参考文献:

- [1] FISHER R A. The use of multiple measurements in taxonomic problems[J]. Annals of Eugenics 1936(7):178~188.
- [2] FOLEY D H, SAMMON J W. An optimal set of discriminant vectors [J]. IEEE Transactions on Computer, 1975, 24(3):281~289.
- [3] CHEN L F, LIAO H Y M, KO M T, et al. A new LDA-based face recognition system which can solve the small sample size problem [J]. Pattern Recognition, 2000, 33(10):1713~1726.
- [4] 刘永俊,陈才扣.最大散度差鉴别分析及人脸识别[J].计算机工程与应用,2006,42(34):208~210.
- [5] 陈才扣,刘永俊,杨静宇.二维最大散度差投影鉴别分析[J].系统仿真学报,2007,19(4):833~835.
- [6] HUANG Y S, SUEN C Y. A method of combining multiple experts for the recognition of unconstrained handwritten numerals[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, 7(1):90~94.
- [7] CONSTANTINIDIS A S, FAIRHURST M C, RAHMAN A F R. A new multi-expert decision combination algorithm and its application to the detection of circumscribed masses in digital mammograms[J]. Pattern Recognition, 2001, 34(8):1528~1537.
- [8] 杨健.线性投影分析的理论与算法及其在特征抽取中的应用研究[D].南京:南京理工大学,2002.
- [9] SUN QUAN-SEN, ZENG SHENG-GEN, LIU YANG, et al. A new method of feature fusion and its application in image recognition[J]. Pattern Recognition, 2005, 38(12):2437~2448.
- [10] 孙权森,曾生根,王平安,等.典型相关分析的理论及其在特征融合中的应用[J].计算机学报,2005,28(9):1524~1533.
- [11] 孙权森,曾生根,杨茂龙,等.基于典型相关分析的组合特征抽取及脸像鉴别[J].计算机研究与发展,2005,42(4):614~621.
- [12] 边肇祺,张学工.模式识别[M].2版.北京:清华大学出版社,1999.
- [13] 程云鹏.矩阵论[M].西安:西北工业大学出版社,1999.