

核典型相关分析特征融合方法及应用

许洁 梁久祯 吴秦 李敏

(江南大学物联网工程学院智能系统与网络计算研究所 无锡 214122)

摘要 构建了一种基于核函数的典型相关分析的特征融合算法。首先,利用核函数将图像矩阵映射到核空间,再抽取同一模式的两组特征向量,在两组特征向量之间建立描述它们的相关性的判据准则函数;然后依此准则函数抽取两组典型投影矢量集;最后通过给定的特征融合策略抽取组合的典型相关特征以用于分类识别。该算法将两组特征向量之间的相关性特征作为有效鉴别信息,既可以很好地融合信息,又可以有效地去除特征之间的信息冗余,并且避免了对映射后的数据矩阵进行分解,从而简化了数据运算。在 AR、PIE、ORL、Yale 人脸数据库及 UCI 手写体数字库上的实验结果证明了该方法的有效性和稳定性。

关键词 核函数,核典型相关分析,特征融合,组合特征抽取,人脸识别

中图分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.1.008

Kernel Canonical Correlation Analysis Feature Fusion Method and Application

XU Jie LIANG Jiu-zhen WU Qin LI Min

(Institute of Intelligent Systems and Network Computing, School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

Abstract A feature fusing algorithm based on kernel canonical correlation analysis (KCCA) was constructed in this paper. First, the image data are mapped through kernel function, and then two groups of feature vectors with the same pattern are extracted and the correlation criterion function between the two groups of feature vectors are established. Secondly, two groups of canonical projective vectors are extracted according to this function. Thirdly, feature fusion for classification is done by using proposed strategy. The advantage of the proposed algorithm lies in the following aspects. Firstly, it suits for information fusion. Secondly, it eliminates the redundant information within the features, and it simplifies the computation without decomposing the mapped matrix and gains more discriminated features. The results of experiments on AR face database, PIE face database, ORL face database, Yale face database and UCI handwritten digit database show that this algorithm is efficient and robust.

Keywords Kernel function, Kernel canonical correlation analysis, Feature fusion, Combined feature extraction, Face recognition

1 引言

随着计算机技术的发展,基于信息融合技术的特征级融合方法已经被人们应用在组合特征提取中,并且取得了较好的应用效果。特征融合优势是明显的,因为对同一模式所提取的不同特征向量反映了模式的不同特性,对它们进行优化组合,既保留了参与融合的多组特征的有效鉴别信息,又消除了特征向量之间的冗余信息。现有的特征融合方法主要分为串行融合方法^[1]和并行融合方法^[2]。近年来 Wechsler H. 等人将特征融合应用于特征提取中,并在人脸及手写体识别中取得了很好的效果^[3]。

而特征提取和维数压缩的结果直接决定了特征融合的效果的好坏。迄今为止,各种降维方法层出不穷,其中最具代表性的方法有:主成分分析(PCA)^[4,5]、典型相关分析

(CCA)^[6,7]和偏最小二乘分析(PLS)。其中 PCA 是一种基于单一特征的降维方法,这在一定程度上限制了有效信息的获取;因此有学者提出了 CCA,CCA 是研究两组随机变量之间相关性的方法,在计算机视觉、信号处理及语音识别等领域都有成功的应用^[8-10];而 PLS 是一种与 CCA 相似的方法,主要用于处理高维小样本问题,在化工领域的应用较为成功^[1-3]。

上述经典统计方法均是基于假定的线性空间,无法提取不同特征之间的非线性关系,而核方法正是解决上述问题的有效方法,因此用核来增强以上统计方法已成为趋势,从而衍生出了核主成分分析^[11](KPCA)、核典型相关分析(KCCA)和核偏最小二乘分析(KPLS)等方法。其中 KCCA 已被 Fyfe^[12]和 Akaho^[13]等人应用于一些初步工作,并且 Shawe-Yaylor 和 Cristian^[14]等人在此基础上取得了更进一步的成果。Borga^[15]等提出将特征值问题表示成两个特征值方程以

到稿日期:2015-04-30 返修日期:2015-06-03 本文受国家自然科学基金项目(61170121,61202312)资助。

许洁(1991-),女,硕士,主要研究方向为数字图像处理;梁久祯(1968-),男,博士,教授,主要研究方向为机器视觉、图像处理等,E-mail: jzliang@jiangnan.edu.cn(通信作者);吴秦(1978-),女,博士,副教授,主要研究方向为模式识别、计算机视觉;李敏(1990-),女,硕士,主要研究方向为数字图像处理。

减少计算时间和特征向量的维数,本文正是在此基础上进行研究;同时为了简化 KCCA 的建立,我们在算法中加入了正则化参数,该方法在实验中取得了良好的效果。

基于核典型相关分析,本文提出了一种不同于传统特征融合思路的组合特征提取方法。首先,将图像矩阵通过核函数映射到核空间,再抽取同一模式的两组特征向量,在两组特征向量之间建立描述它们的相关性的判据准则函数;然后依此准则函数抽取两组典型投影矢量集;最后通过给定的特征融合策略抽取组合的典型相关特征并将其应用于分类识别。在多个数据库上的实验结果表明,本文所提出的组合特征提取算法既能很好地融合信息,又能有效地去除特征之间的冗余信息,得到具有较好鉴别力的分类特征。

2 典型相关分析理论在特征融合中的应用

2.1 典型相关分析的基本思想

典型相关分析的思想最早由 Hotelling 在 1936 年发起^[16],旨在简化多元统计分析中经常要研究的两组随机变量之间的相关性问题,即将两组随机变量之间的相关性研究转化成两组中为数不多的相互之间不相关的几对变量之间的相关性研究。

典型相关分析的基本思想具体如下:构造两个零均值的随机变量 $x \in R^p$ 和 $y \in R^q$,并找到一对投影方向 α 与 β ,使得投影 $x_1^* = \alpha^T x$ 与 $y_1^* = \beta^T y$ 之间具有最大的相关性。而这种相关通常被称为典型相关。 x_1^*, y_1^* 为第一对典型变量;接着可以由 x, y 出发,找出第二对典型变量 x_2^*, y_2^* ,要求 x_2^*, y_2^* 与第一对典型变量 x_1^*, y_1^* 不相关,但 x_2^* 与 y_2^* 之间必须满足典型相关的要求。如此执行下去,将 x 与 y 的所有相关性特征全部提取出来。这样只需要分析提取的典型变量中的少数几对相关关系就可以得到 x 与 y 之间的相关性分析结果。

如下为获得投影方向的准则函数,一般通过最大化该函数即可获得 α 与 β 。

$$\begin{aligned} \rho &= \frac{E[\alpha^T x y^T \beta]}{\sqrt{E[\alpha^T x x^T \alpha] \cdot E[\beta^T y y^T \beta]}} \\ &= \frac{\alpha^T E[x y^T] \beta}{\sqrt{\alpha^T E[x x^T] \alpha \cdot \beta^T E[y y^T] \beta}} \\ &= \frac{\alpha^T S_{xy} \beta}{\sqrt{\alpha^T S_{xx} \alpha \cdot \beta^T S_{yy} \beta}} \end{aligned} \quad (1)$$

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

2.2 联合特征抽取的原理与算法

假设有如 $\omega_1, \omega_2, \dots, \omega_c$ 的 c 个模式类,模式 ξ 是 n 维实向量,训练样本空间为 $\Omega = \{\xi | \xi \in R^n\}$ 。令 $A = \{x | x \in R^p\}, B = \{y | y \in R^q\}$ 。

x 与 y 是随机向量空间 (A, B) 的随机向量,提取 x 与 y 之间的典型相关特征,记为 $\alpha_d^T x$ 与 $\beta_d^T y$ (第 d 对)。将式(2)与式(3)分别看作是变换后的特征分量:

$$X^* = (\alpha_1^T x, \alpha_2^T x, \dots, \alpha_d^T x)^T = (\alpha_1, \alpha_2, \dots, \alpha_d)^T x = W_x^T x \quad (2)$$

$$Y^* = (\beta_1^T y, \beta_2^T y, \dots, \beta_d^T y)^T = (\beta_1, \beta_2, \dots, \beta_d)^T y = W_y^T y \quad (3)$$

其经过如式(4)所示的线性变换后作为投影后的组合特征并应用于分类中。

$$Z = \begin{bmatrix} X^* \\ Y^* \end{bmatrix} = \begin{bmatrix} W_x^T x \\ W_y^T y \end{bmatrix} = \begin{bmatrix} W_x & 0 \\ 0 & W_y \end{bmatrix}^T \begin{bmatrix} x \\ y \end{bmatrix} \quad (4)$$

$$\text{其中变换矩阵为: } W = \begin{bmatrix} W_x & 0 \\ 0 & W_y \end{bmatrix}.$$

为了讨论典型投影向量和典型相关特征的求法与性质,建立如下准则函数:

$$J_{CCA}(\alpha, \beta) = \frac{\alpha^T S_{xy} \beta}{\sqrt{\alpha^T S_{xx} \alpha \cdot \beta^T S_{yy} \beta}} \quad (5)$$

本节只讨论 S_{xx} 与 S_{yy} 都是非奇异的情况。

为了保证解的唯一性,令:

$$\alpha^T S_{xx} \alpha = \beta^T S_{yy} \beta = 1 \quad (6)$$

问题变为:在式(6)的约束条件下,求解典型投影向量 α 与 β ,使准则函数式(5)取得最大值。

通过求解式(7)的最优化问题,得到第 k 对投影向量:

$$\begin{cases} \max J(\alpha, \beta) \\ \alpha^T S_{xx} \alpha = \beta^T S_{yy} \beta = 1 \\ \alpha_i^T S_{xx} \alpha = \beta_i^T S_{yy} \beta = 0 (i < k) \\ \alpha \in R^p, \beta \in R^q \end{cases} \quad (7)$$

根据拉格朗日乘法,再利用奇异值分解定理可得到满足最优化问题中约束条件的典型投影向量。

定理 1^[17] 令 $\alpha_i = S_{xx}^{-1/2} u_i, \beta_i = S_{yy}^{-1/2} v_i, i = 1, 2, \dots, r$, 则有:

(1) G_1 与 $S_{yy}^{-1} S_{xy} S_{xx}^{-1} S_{xy}$ (G_2 与 $S_{xx}^{-1} S_{xy} S_{yy}^{-1} S_{xy}$) 具有相同的非零特征值,并且满足 $1 \geq \lambda_1^2 \geq \lambda_2^2 \geq \dots \geq \lambda_r^2 > 0$ ($r = \text{rank}(S_{xy})$) ($\frac{\pi}{2} - \theta$)。

(2) α_i 和 β_i 分别对应于特征值 λ_i^2 的特征向量,并且有 $\alpha_i = \lambda_i^{-1} S_{xx}^{-1} S_{xy} \beta_i, \beta_i = \lambda_i^{-1} S_{yy}^{-1} S_{xy} \alpha_i$ 。

$$(3) \begin{cases} \alpha_i^T S_{xx} \alpha_j = \beta_i^T S_{yy} \beta_j = \delta_{ij} \\ \alpha_i^T S_{xx} \beta_j = \lambda_i \delta_{ij} \end{cases} \quad (8)$$

其中, $\delta_{ij} = \begin{cases} 1, & i=j \\ 0, & i \neq j \end{cases}, i, j = 1, 2, \dots, r$ 。

通过上述定理可以得到满足约束条件并且使目标函数 $J(\alpha, \beta)$ 达到极值的解,也就是最优化问题的最优解。

算法步骤如下:

第一步:构建训练样本空间 A, B ;抽取同一模式的两组不同特征向量,变换原模式空间。

第二步:分别计算训练样本空间 A, B 中的协方差矩阵 S_{xx}, S_{yy} 和互协方差矩阵 S_{xy} 。

第三步:根据定理 1,计算出矩阵 G_1 和矩阵 G_2 的非零特征值 $\lambda_1^2 \geq \lambda_2^2 \geq \dots \geq \lambda_r^2$ 及其对应的标准正交特征向量 $u_i, v_i (i = 1, 2, \dots, r)$ 。

第四步:基于定理 1,计算所有典型投影向量 $\alpha_i, \beta_i (i = 1, 2, \dots, r)$,取前 d 对投影向量构成典型投影矩阵 W_x 和 W_y 。

第五步:利用上述线性变换式(4)提取组合特征并进行分类。

3 核典型相关分析特征融合方法

由 2.1 节可知,求两组随机变量之间的相关系数公式为:

$$\rho = \frac{\alpha^T S_{xy} \beta}{\sqrt{\alpha^T S_{xx} \alpha \cdot \beta^T S_{yy} \beta}} \quad (9)$$

因为 α 和 β 的范数乘积决定了相关联函数的泛化质量,所以在 α 和 β 之前加上惩罚因子,则式(9)变为:

$$\rho = \frac{\alpha^T S_{xy} \beta^T}{\sqrt{(\alpha^T S_{xx} \alpha + k \|\alpha\|^2) \cdot (\beta^T S_{yy} \beta + k \|\beta\|^2)}} \quad (10)$$

现在将 X 与 Y 映射到高维特征空间,变为 $\phi(X)$ 、 $\phi(Y)$,此时

$$\phi(X) = [\phi(x_1^*), \phi(x_2^*), \dots, \phi(x_p^*)] \quad (11)$$

$$\phi(Y) = [\phi(y_1^*), \phi(y_2^*), \dots, \phi(y_q^*)]$$

根据核函数的定义,核的计算式为:

$$k(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle = \langle \phi(x_j), \phi(x_i) \rangle = k(x_j, x_i) \quad (12)$$

其中, $\langle \rangle$ 表示两个向量之间的内积。

由式(11)和式(12)可以得到 $p \times p$ 的核矩阵也就是 Gram 矩阵,有

$$K = \phi^T(X) \phi(X) \quad (13)$$

其中, $K = (k_{ij}) (i=1, 2, \dots, p; j=1, 2, \dots, q)$, 故

$$\alpha_{\phi(X)} = \phi(X) a_{\phi(X)}, \beta_{\phi(Y)} = \phi(Y) b_{\phi(Y)} \quad (14)$$

其中, $\alpha_{\phi(X)}$ 、 $\beta_{\phi(Y)}$ 是在高维空间中的投影方向; $a_{\phi(X)}$ 、 $b_{\phi(Y)}$ 是另一组系数。联立式(12)和式(13),代入约束条件式(6)中,得到

$$\begin{aligned} \alpha_{\phi(X)}^T \phi^T(X) \phi(X) \alpha_{\phi(X)} \\ = \alpha_{\phi(X)}^T \phi(X) \phi^T(X) \phi(X) \phi^T(X) \alpha_{\phi(X)} \\ = \alpha_{\phi(X)}^T K K \alpha_{\phi(X)} = 1 \end{aligned} \quad (15)$$

同理,另一个约束条件为

$$\beta_{\phi(Y)}^T \phi^T(Y) \phi(Y) \beta_{\phi(Y)} = b_{\phi(Y)}^T K K b_{\phi(Y)} = 1 \quad (16)$$

因此,由式(13)一式(15)可以求得约束条件为

$$\begin{cases} \alpha_{\phi(X)}^T K_x K_x \alpha_{\phi(X)} + K a_{\phi(X)}^T K_x K_x a_{\phi(X)} = 1 \\ b_{\phi(Y)}^T K_y K_y b_{\phi(Y)} + K b_{\phi(Y)}^T K_y K_y b_{\phi(Y)} = 1 \end{cases} \quad (17)$$

到此为止, KCCA 就转换成了一个最优化问题。

对上述最优化问题进行求解。利用拉格朗日乘数法,可以得到(为了简化,令 $a_{\phi(X)} = a$, $b_{\phi(Y)} = b$):

$$\begin{aligned} L(\lambda_x, \lambda_y, a, b) = a^T K_x K_x a - \frac{\lambda_x}{2} (a^T K_x K_x a + k a^T K_x a - \\ 1) - \frac{\lambda_y}{2} (b^T K_y K_y b + k b^T K_y b - 1) \end{aligned} \quad (18)$$

分别对 a, b 求偏导,有

$$\begin{cases} \frac{\partial L}{\partial a} = K_x K_x b - \lambda_x (K_x^2 a + k K_x a) = 0 \\ \frac{\partial L}{\partial b} = K_y K_x a - \lambda_y (K_y^2 b + k K_y b) = 0 \end{cases} \quad (19)$$

将式(19)中第1式左乘 a^T ,第2式左乘 b^T ,再将两式相减得

$$0 = \lambda_y b^T (K_y^2 b + k K_y b) - \lambda_x a^T (K_x^2 a + k K_x a) \quad (20)$$

又 $\lambda_x = \lambda_y = \lambda$,从而可以推导出

$$b = \frac{(K_y + kI)^{-1} K_y^{-1} K_y K_x a}{\lambda} = \frac{(K_y + kI)^{-1} K_x a}{\lambda} \quad (21)$$

将其代入式(19)第1式得到只含 a 的特征方程:

$$(K_x + kI)^{-1} K_x (K_y + kI)^{-1} K_x a = \lambda^2 a \quad (22)$$

解方程式(22),即可求得特征值 $\lambda_i > 0$ 和对应的 a 。

4 实验与分析

本文实验是在 Matlab R2014a 平台上进行的,所用的计算机系统配置如下:CPU 为 Intel(R) Core(TM) i5-2430;主

频为 @2.40GHz;内存为 4GB;操作系统为 Microsoft Windows7 Professional。

本文方法的主要实验步骤为:首先将数据库上的所有图片转成矩阵形式,并按序存放,得到一个总矩阵;然后大致从中间切割该矩阵得到两个子矩阵,并用 KCCA 算法对它们进行降维,得到两组特征;最后对这两组特征做加法后得到融合后的特征。

本文实验中所采用的核函数均为高斯核函数,核参数 KParx/KPary 的取值范围为 $[10^{-5}, 10^{-4}, \dots, 10^3, 10^4, 10^5]$,正则化参数 RParx/KPary 的取值范围为 $[0.001, 0.0001, \dots]$ 。本文实验的参数是通过参考其他论文的参数值,并进行大量的实验验证比较之后选取的使实验结果较为理想的参数值。

4.1 AR 人脸数据库上的特征融合实验

本实验在 AR 人脸数据库的一个子库上进行,该数据库由西班牙巴塞罗那计算机视觉中心创建。AR 人脸数据库中一共有 1680 幅图像,是由 120 位志愿者每人 14 幅图像组成的。该人脸库中每幅图像的分辨率为 40×50 。每个人的每一幅图像都有相对较大的光照变化、表情变化以及姿态变化。图 1 为 AR 人脸库中一个人的 6 幅图像。



图 1 AR 人脸数据库中一个人的 6 幅图像

在 AR 人脸数据库上与其他算法对比的实验结果如表 1 所列。在 AR 人脸库上选取 10 人做实验,以每人的前 7 幅图像作为训练样本,后 7 幅图像作为测试样本。训练样本和测试样本的总数分别为 70 和 70。另外,本文所有的实验均采用最近邻分类器。本次实验中存储两组特征向量维数的数组 FVDim = $[900, 900]$,核参数类型 KType = 1,核参数 KParx = 10^5 ,KPary = 10^5 ,第一组特征的正则化参数 RParx = 0.0001,第二组特征的正则化参数 RPary = 0.0001。

表 1 AR 人脸数据库识别率对照表

维数	KCCA	KPLS	CCA	PCA
5	0.78571	0.71429	0.35714	0.74286
10	0.94286	0.75714	0.42857	0.88571
15	0.95714	0.75714	0.55714	0.88571
20	0.95714	0.75714	0.62857	0.88571
25	0.95714	0.75714	0.62857	0.87143
30	0.95714	0.75714	0.62857	0.87143
35	0.95714	0.75714	0.55714	0.87143
40	0.95714	0.75714	0.54286	0.87143
45	0.95714	0.75714	0.57143	0.87143
50	0.95714	0.75714	0.51429	0.87143

观察表 1 可知,当维数在 10 以上时, KCCA 算法的识别率已经可以达到并稳定在 95.7%,明显高于 PCA 算法(87.1%)和 KPLS 算法(75.7%)的识别率。通过观察大量实验数据可以发现,存在一个极值点,过了该点之后,即使子空间维数增加,识别率也不会超过这个点,这就说明不是所有的特征向量都代表了有效的人脸信息,有的可能是与人脸信息无关的噪声、背景等无效信息,将这些特征向量作为子空间的基,会导致识别率的下降。

4.2 ORL 人脸数据库上的特征融合实验

为了进一步验证本文的算法在人脸姿态变化较大的情况下对识别率的影响,本实验采用 ORL 标准人脸库。ORL 人脸数据库由剑桥大学 AT&T 实验室创建。该人脸数据库由 40 位志愿者、每人 10 幅分辨率为 112×92 的图像组成,其中有些图像拍摄于不同的时期,人脸的姿态有一定程度的变化,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。部分志愿者的图像还包括了表情以及面部饰物的变化。图 2 显示了该人脸数据库中一个人的 6 幅图像。



图 2 ORL 人脸数据库中一个人的 6 幅图像

在 ORL 人脸数据库上与其他算法对比的实验结果如图 3 所示。在 ORL 人脸数据库中选取 10 人做实验,以每人的前 5 幅图像作为训练样本,后 5 幅图像作为测试样本,训练样本和测试样本总数分别为 50 和 50。本次实验存储两组特征向量维数的数组 $FVDim=[5000,5000]$,核参数类型 $KType=1$,核参数 $KParx=10^5$, $KPary=10^5$,正则化参数 $RParx=0.001$, $RPary=0.001$ 。




图 3 ORL 人脸数据库识别率的对比

由图 3 可以看出,当维数为 $0 \sim 10$ 时,4 种算法的识别率都上升得很快;当维数在 10 以上时,KCCA 算法的识别率已经可以达到并稳定在 92% 左右,明显高于 KPLS 算法 (86%) 和 CCA 算法 (62%) 的识别率,略低于 PCA 算法 (94%) 的识别率。由于 ORL 人脸数据库中有部分图像拍摄于不同的时期,人脸的姿态有一定程度的旋转变化,人脸的尺度也有一定角度的变化,因此该实验结果表明,本文的算法对人脸姿态的变化具有一定的鲁棒性。

4.3 PIE 人脸数据库上的特征融合实验

本实验在 PIE 人脸数据库的一个子库上进行,该数据库由美国卡耐基梅隆大学创立。PIE 人脸数据库中一共有 2040 幅图像,是由 51 位志愿者、每人 40 幅图像组成的。该人脸库中每幅图像的分辨率为 64×64 。该数据库中每幅图像都有相对较大的光照变化以及角度变化,为实验结果的可靠性打下了坚实的基础。图 4 为 PIE 人脸库中一个人的 6 幅图像。



图 4 PIE 人脸数据库中一个人的 6 幅图像

在 PIE 人脸数据库上与其他算法对比的实验结果如表 2 所列。在 PIE 库上选取 40 人做实验,以每人的前 20 幅图像

作为训练样本,后 10 幅图像作为测试样本。训练样本和测试样本的总数分别为 800 和 400。本次实验中存储两组特征向量维数的数组 $FVDim=[1900,1900]$,核参数类型 $KType=1$,核参数 $KParx=10^5$, $KPary=10^5$,正则化参数 $RParx=0.001$, $RPary=0.001$ 。

表 2 PIE 人脸数据库识别率对照表

维数	KCCA	KPLS	CCA	PCA
5	0.3475	0.0625	0.0375	0.1925
10	0.675	0.0875	0.0825	0.38
15	0.8	0.0875	0.1225	0.54
20	0.82	0.0875	0.165	0.605
25	0.8425	0.0875	0.2175	0.6175
30	0.8575	0.0875	0.23	0.655
35	0.865	0.0875	0.2825	0.68
40	0.875	0.09	0.3025	0.6825
45	0.88	0.09	0.3325	0.68
50	0.885	0.09	0.39	0.69

由表 2 可以看出,KCCA 算法的识别率可以达到并保持 88.5%,明显高于 PCA 算法 (69.0%)、CCA 算法 (39.0%) 和 KPLS 算法 (9.0%) 的识别率。由于 PIE 人脸数据库中人脸有较大的光照变化,因此实验结果表明本文方法对光照变化具有一定的鲁棒性。另外观察表 2 可知,本文方法的准确性和稳定性都远远好于 CCA 算法,这表明在 CCA 的基础上引入核函数之后,能够获得更有效的相关性特征,提高了分类的正确率。

4.4 Yale 人脸数据库上的特征融合实验

本实验在 Yale 标准人脸数据库上进行,该数据库由耶鲁大学计算机视觉与控制中心创建。Yale 标准人脸数据库中一共有 165 幅图像,是由 15 位志愿者、每人 11 幅图像组成的。该人脸库中每幅图像的分辨率为 100×80 。从不同的角度来获取每个人的每一幅图像,并且每幅图像都有相对较大的光照变化、表情变化、部分缺损以及姿态变化。图 5 为 Yale 标准人脸库中一个人的 6 幅图像。



图 5 Yale 人脸数据库中一个人的 6 幅图像

在 Yale 标准人脸数据库上与其他算法对比的实验结果如图 6 所示。本次实验以每人的前 5 幅图像作为训练样本,后 6 幅图像作为测试样本。训练样本和测试样本的总数分别为 75 和 90。本次实验中存储两组特征向量维数的数组 $FVDim=[3900,3900]$,核参数类型 $KType=1$,核参数 $KParx=10^5$, $KPary=10^5$,正则化参数 $RParx=0.001$, $RPary=0.001$ 。




图 6 Yale 人脸数据库识别率的对比

Yale 人脸数据库是从不同的角度来获取的每个人的每一幅图像,并且每幅图像都有相对较大的光照变化、表情变化、部分缺损以及姿态变化。由图 6 可以看出,最终 KCCA 算法的识别率可达到并稳定在 88.8% 左右,明显高于 KPLS 算法(84.4%)和 CCA 算法(63.3%)的识别率,但低于 PCA 算法(92.2%)的识别率。比较 KCCA 和 CCA 算法的识别率曲线可知,核技术的引入使得 KCCA 算法在最近邻分类器下取得了较好的分类结果,且本文算法对光照、表情以及姿态的变化具有一定的鲁棒性。

4.5 UCI 手写体数字库上的特征融合实验

本实验在 UCI 手写体数字库上进行,UCI 手写体数字库是由加州大学欧文分校提出的用于机器学习的数据库。该数据库是由 0,1,2...9 这 10 个数字、每个数字 200 个样本组成的,其中第 1~200 列为数字 0 的样本,第 201~400 列为数字 1 的样本,以此类推。

在 UCI 手写体数字库上与其他算法对比的实验结果如图 7 所示。本次实验以每个数字的前 50 个作为训练样本,接下来的 20 个作为测试样本。训练样本和测试样本的总数分别为 500 和 200。本次实验存储两组特征向量维数的数组 $FVDim=[300,300]$,核参数类型 $KType=1$,核参数 $KParx=10^3$, $KPary=10^4$,正则化参数 $RParx=0.001$, $RPary=0.001$ 。




图 7 UCI 手写体数字库识别率的对比

由于 UCI 手写体数字库中所识别的类只有手写的 0 到 9 这 10 个数字,很容易分类,因此识别的准确率较高。由图 7 可以看出,当维数在 10 以上时,KCCA 和 PCA 算法的识别率都可以达到并保持在一个较高的水平(94%左右),并且都高于 KPLS 和 CCA 算法的识别率,尤其比 CCA 算法的识别率高出很多,这表明 KCCA 所抽取的特征在组合之后具有很强的分类能力,是一种非常有效的组合特征抽取方法,并且不仅适用于人脸的识别,也同样能应用在手写体数字的识别中。

结束语 本文首先介绍了典型相关分析以及联合特征抽取的原理与算法,然后对核技术进行了简要介绍,并对核典型相关分析问题进行了建模和求解,最后在 AR、PIE、ORL、Yale 人脸数据库及 UCI 手写体数字库上进行了实验,证明了本文提出的方法能有效地融合已有的特征,并消除特征之间的信息冗余,在分类中取得很好的结果。当同一模式的两组训练样本空间的总体散布矩阵均奇异时,如何提取它们的典型相关特征;两组特征之间满足什么条件时组合后的特征抽取更有利于分类识别,也是值得探讨的问题。这些都是我们下一阶段要研究的内容。

- [1] Liu C, Wechsler H. A shape and texture-based enhanced Fisher classifier for face recognition[J]. IEEE Transactions on Image Processing, 2001, 10(4): 598-608
- [2] Yang J, Yang J. Generalized K-L transform based combined feature extraction[J]. Pattern Recognition, 2002, 35(1): 295-297
- [3] Yang J, Yang J, Zhang D, et al. Feature fusion: parallel strategy vs. serial strategy[J]. Pattern Recognition, 2003, 36(6): 1369-1381
- [4] Fukunaga K. Introduction to statistical pattern recognition[M]. Academic press, 2013
- [5] Worley B, Halouska S, Powers R. Utilities for quantifying separation in PCA/PLS-DA scores plots[J]. Analytical biochemistry, 2013, 433(2): 102-104
- [6] Mercer T G, Frostick L E. Leaching characteristics of CCA-treated wood waste; a UK study[J]. Science of the Total Environment, 2012, 427: 165-174
- [7] Hu G D, Zhang R C. Multivariate data analysis methods: Purely algebraic treatment[M]. Tianjin: Nankai University Press, 1990 (in Chinese)
胡国定, 张润楚. 多元数据分析方法: 纯代数处理[M]. 天津: 南开大学出版社, 1990
- [8] Protásio T D P, Trugilho P F, Neves T A, et al. Canonical correlation analysis between characteristics of Eucalyptus wood and charcoal[J]. Scientia Forestalis, 2012, 40(95): 317-326
- [9] Hong S, Chen X, Jin L, et al. Canonical correlation analysis for RNA-seq co-expression networks[J]. Nucleic acids research, 2013, 41(8): e95
- [10] Lin D, Zhang J, Li J, et al. Group sparse canonical correlation analysis for genomic data integration[J]. BMC bioinformatics, 2013, 14(1): 245
- [11] Chang P C, Wu J L. A critical feature extraction by kernel PCA in stock trading model[J]. Soft Computing, 2015, 19(5): 1393-1408
- [12] Lai P L, Fyfe C. Kernel and nonlinear canonical correlation analysis[J]. International Journal of Neural Systems, 2000, 10(5): 365-377
- [13] Akaho S. A kernel method for canonical correlation analysis[C]// Proceedings of the International Meeting of the Psychometric Society(MPS 2001). 2001
- [14] Joachims T, Cristianini N, Shawe-Taylor J. Composite kernels for hypertext categorisation[C]// Proceeding of the Eighteenth International Conference on Machine Learning. Morgan Kaufmann Publishers Inc., 2001: 250-257
- [15] Knutsson H, Borga M. Learning multidimensional signal processing[D]. Linköping University, 1998
- [16] Hotelling H. Relations between two sets of variates [J]. Biometrika, 1936, 28(314): 321-377
- [17] Sun Q S. Research on feature extraction and image recognition based on correlation Projection analysis[D]. Nanjing: Nanjing University of Science and Technology, 2006 (in Chinese)
孙权森. 基于相关投影分析的特征抽取与图像识别研究[D]. 南京: 南京理工大学, 2006