

核典型相关分析的融合人脸识别算法

王大伟^{1,2}, 陈浩^{1,2}, 王延杰¹

(1. 中国科学院长春光学精密机械与物理研究所, 吉林 长春 130033; 2. 中国科学院研究生院, 北京 100039)

摘要:为了更有效地映射图像数据样本到可分类特征空间,提高分类正确率,提出了一种新的基于核函数的典型相关分析的融合人脸识别算法。该方法首先把图像矩阵通过核函数映射到核空间,然后从核空间的行和列两个方向进行特征抽取,同时避免分解映射后的数据矩阵,简化了数据运算,获得了更具鉴别力的分类特征。在 Ohio 州立大学的 OTCBVS 可见/红外人脸数据库中进行了分类识别实验,实验结果表明:该方法可以获得 90% 以上的识别正确率,优于其他的典型相关分析的人脸识别方法的分类正确率。此外,对不均匀光照变化,表情变化等人脸识别的常见问题具有很好的抵抗能力。

关键词:典型相关分析;核典型相关分析;特征级图像融合;人脸识别

中图分类号:TP391.4 **文献标识码:**A

Fusing facial feature recognition algorithm based on kernel canonical correlation analysis

WANG Da-wei^{1,2}, CHEN Hao^{1,2}, WANG Yan-jie¹

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;
2. Graduate School of the Chinese Academy of Sciences, Beijing 100039, China)

Abstract: A new fusing facial feature recognition algorithm based on kernel Canonical Correlation Analysis (Kernel CCA) was proposed, for mapping image data into feature space and improving classifying accuracy. In our approach, we first map the image data through kernel function, then extract feature from the directions of rows and columns. Our algorithm simplifies the computation without decomposing the mapped matrix and gains the more discriminated features. The experiment results on OTCBVS V/IR face database of Ohio state university show that our algorithm gets better performance than other facial recognition method based on CCA with recognition accuracy more than 90%. In addition, it also can get the excellent results with the illumination and expression variance.

Key words: canonical correlation analysis; kernel canonical correlation analysis; feature-level image fusion; face recognition

1 引言

典型相关分析(Canonical correlation analysis, CCA)是由 Hotelling 提出的一种经典的多元数据统计方法,它是一种分析数据间的线性独立性的数学方法,并已经被应用于手势识别^[1]、盲源均衡^[2]和气候变化分析^[3]。基于典型相关分析理论的融合方法是利用 CCA 的思想,建立两组特征向量之间的相关性准则函数,求得投影矢量集,然后提取组合的

典型相关特征。文献[4]提出了一种奇异情况下典型相关特征的提取过程:首先利用 PCA 降维,然后再进行 CCA。基于图像矩阵的思想,文献[5]提出了二维典型相关分析方法(2DCCA),它直接利用图像的矩阵表达形式进行相关投影分析,提高了特

作者简介:王大伟(1983-),男,博士研究生,研究方向为机器视觉,目标识别。E-mail:wdwei1983@163.com

收稿日期:2009-04-28;修订日期:2009-06-22

征的抽取速度,并探讨了 CCA 用于模式识别中的高维小样本问题,都取得了不错的识别正确率。然而,典型相关分析存在着一个固有的问题,如果数据是非高斯分布的,或者不是近似呈椭球对称分布的,典型相关分析就不能正确描述数据之间的空间分布关系^[6]。Akaho 于 2001 年提出了核典型相关分析 (KCCA)^[7],接着 Melzer 讨论了基于 KCCA 的 appearance 模型^[8]。

本文讨论了核典型相关分析的原理,提出了一种新的核典型相关矢量的求解方法,无需分解在核变换空间的数据,试验结果表明核典型相关分析的人脸识别方法,优于已有的 2DCCA 和 PCA + CCA 的方法,且对人脸表情和光照变化有很好的抵抗能力。

2 典型相关分析的特征融合

2.1 典型相关分析概述

最初的典型相关分析,也被称作线性典型相关分析 (LCCA),仅仅用于描述数据间的线性关系。随机矢量 $(x_i, y_i), i = 1, \dots, m$, 通过某种线性变换能够提取出特定线性子空间的特征用于维数约减和特征选择。从机器学习的角度来讲,更类似于认为 x_i 描述了第 i 个观察量而相应的 y_i 描述了目标的类别隶属度。若假设数据为高斯分布, LCCA 也可以用于计算两组随机变量间的随机独立性^[9]。通常,两个矩阵间的独立性由 F 范数度量。

具体来说,给出一对零均值随机矢量 $x \in R^{m_1}, y \in R^{m_2}$, 有变换关系 α, β , 称作典型相关变换,它通过式(1)计算变换矢量 $x' = \alpha x$ and $y' = \beta y$ 的最大相关参数:

$$\arg \max_{\alpha, \beta \in R^{m_1+m_2}} \rho = \frac{x'^T y'}{\|x'\| \times \|y'\|} = \frac{\alpha' C_{12} \beta}{\sqrt{\alpha' C_{11} \alpha \beta' C_{22} \beta}} \quad (1)$$

式中, C_{ij} 是矢量 x 和 y 的协方差矩阵, $i, j = 1, 2$, 实际上,式(1)就是解如下的优化问题:

$$\rho = \arg \max_{\alpha, \beta \in R^{m_1+m_2}} \alpha' C_{12} \beta \quad \text{Subject to } \alpha' C_{11} \alpha = 1 \text{ and } \beta' C_{22} \beta = 1 \quad (2)$$

最优解可以通过求取如式(3)所示的广义特征值问题的最大特征值对应的特征向量获得:

$$\begin{bmatrix} 0 & C_{12} \\ C_{21} & 0 \end{bmatrix} \times \text{vect} = \rho \times \begin{bmatrix} C_{11} & 0 \\ 0 & C_{22} \end{bmatrix} \times \text{vect} \quad (3)$$

这里, ρ 是典型相关系数 (canonical correlation), 而 $\text{vect} = [\alpha^T, \beta^T]^T$ 是特征矢量。

2.2 核典型相关分析

在实际分类问题中,时常存在线性相关不足以

描述矢量 α 和 β 之间的相关性的情况。一个解决方法是引入核函数,核函数是模式识别领域广泛使用的变换方法,它最初引起广泛的关注是因为在支持向量机中的巨大成功。核函数方法的原理就是通过替换线性内积为核函数,把线性算法构造非线性的变量计算。在一定条件下,这些核函数可以解释为表达目标数据的内积,其隐含在相关特征空间的非线性映射中。一组常用的实值函数被引入用于核化典型相关分析,如下所示:

$$K(x, x_i) = (x \cdot x_i + 1)^q \quad (4)$$

$$K(x, x_i) = \exp\left(-\frac{|x - x_i|^2}{\sigma^2}\right) \quad (5)$$

$$K(x, x_i) = \tanh(v(x \cdot x_i) + c) \quad (6)$$

式(4)是多项式内积函数;式(5)是径向基函数;式(6)是 sigmoid 函数。这里我们假定 K_u, K_v 是两个分别定义于 $R^{m_1} \otimes R^{m_1}$ 和 $R^{m_2} \otimes R^{m_2}$ 空间的正的核函数,而 $K = K_u \oplus K_v$ 是一个定义于 $(R^{m_1} \oplus R^{m_2}) \times (R^{m_1} \oplus R^{m_2})$ 空间的正的核函数。如线性典型相关分析类似,核典型相关分析 (KCCA) 也就是寻找典型相关矢量 $\alpha_j, \beta_j \in R^m$, 所以式(1)可以变换为式(7):

$$\rho = \max_{\alpha, \beta \in R^{m_1+m_2}} \frac{\alpha^T K_u K_v \beta}{\sqrt{(\alpha^T K_u K_u \alpha)(\beta^T K_v K_v \beta)}} \quad (7)$$

相应地得到如下的优化问题:

$$\rho = \max_{\alpha, \beta \in R^{m_1+m_2}} \alpha^T K_u K_v \beta \quad (8)$$

$$\text{Subject to } \alpha^T K_u K_u \alpha = \beta^T K_v K_v \beta = 1$$

从上面的论述可知,核化是 KCCA 的重要步骤。

3 核相关分析的识别算法

假设将输入向量 X 通过一个非线性函数 Φ 映射到高维空间 F 中, $\Phi: x \rightarrow \Phi(x) \in F$, 而且需要把映射后的数据中心化,即满足: $\sum_{i=1}^N \bar{\Phi}(x_i) = 0$ 。然后对中心化的数据核化,然后对其进行典型相关分解,通过核函数映射后的数据可以奇异值分解为: $K_x = V \Lambda V^T, U_x = \Phi_x^T A_x$, 这里 $A_x = (V \Lambda^{-1/2})_d$, 即 $V \Lambda^{-1/2}$ 的前 d 维。令 $C_x = \Phi_x U_x = K_x A_x$, 目的是找到数据在核变换空间的典型相关性,进而求出待识别的数据在典型投影矢量变换矩阵下的特征,最后根据分类判据进行分类。

$$(C_x^T C_x)^{-1} C_x^T C_y (C_y^T C_y)^{-1} C_y^T C_x \varphi_i = \lambda_i^2 \varphi_i \quad (9)$$

$$(C_y^T C_y)^{-1} C_y^T C_x (C_x^T C_x)^{-1} C_x^T C_y \xi_i = \lambda_i^2 \xi_i \quad (10)$$

典型相关矢量可以由式(11)、式(12)求得:

$$v_i = \Phi_x A_x \varphi_i \quad (11)$$

$$w_i = \Phi_y A_y \xi_i \quad (12)$$

从而相应的典型相关特征可以通过式(13)、式(14)求得:

$$a_i = K_x A_x \varphi_i \quad (13)$$

$$b_i = K_y A_y \xi_i \quad (14)$$

令 $H = (C_x^T C_x)^{-1/2} (C_x^T C_y) (C_y^T C_y)^{-1/2}$, 应用奇异值分解定理: $H = \sum_{i=1}^r \lambda_i u_i v_i^T$ ($i = 1, 2, \dots, r$), 其中 $\lambda_1^2 \geq \lambda_2^2 \geq \dots \geq \lambda_r^2$ 是 $G_1 = H^T H$ 与 $G_2 = H H^T$ 的非零特征值, u_i 与 v_i 分别为 G_1 与 G_2 对应于 λ_i^2 的单位正交的特征矢量。在实际问题中, 我们无需关心数据在核变换空间的典型相关性, 而只要求出映射后的数据在典型投影矢量变换矩阵下的特征。这样, 我们提出的基于核函数的典型相关分析算法可以总结如下:

1) 计算两组图像集的均值: $\bar{A} = \frac{1}{N} \sum_{i=1}^N A_i, \bar{B} =$

$\frac{1}{N} \sum_{i=1}^N B_i$, 然后为避免矩阵奇异, 引入扰动矩阵 λ , 其元素的值在 $[0, 1]$ 之间;

2) 通过核函数 $Kx = \langle \phi(x_i), \phi(x_j) \rangle, Ky = \langle \phi(y_i), \phi(x_j) \rangle$ 变换 \bar{A}, \bar{B} ;

3) 计算 G_1 与 G_2 的非零特征值 $\lambda_1^2 \geq \lambda_2^2 \geq \dots \geq \lambda_r^2$ 对应的特征向量 u_i 与 v_i ;

4) 由 $\alpha = S_{xx}^{-1/2} u_i$ 与 $\beta = S_{yy}^{-1/2} v_i$, 这里 $S_{xx} = \frac{1}{N-1} (K_x K_x), S_{yy} = \frac{1}{N-1} (K_y K_y)$, 计算出典型投影矢量, 并由求得的典型投影矢量组成变换矩阵 W_x 与 W_y ;

5) 利用线性变换抽取组合特征, 并采用模式分类中常用的最小距离分类器用于分类。

4 留一交互验证方法

采用模式识别试验中经常采用的留一交互验证 (leave-one-out cross validation) 的方法用于分类正确率估计。留一交互验证的基本思想是: 每次从总体中拿出一个样本作为测试样本, 把其余 $(N-1)$ 个样本作为训练集, 这样重复 N 次, 直到所有样本都被作为测试样本试验过。

采用常用的 k 近邻法作为分类器, 如图 1 所示。从字面上看, 这个方法就是取未知样本 x 的 k 个近邻, 看这 k 个近邻中多数属于哪一类就把 x 归为哪一类。具体说就是在 N 个已知的样本中找出 x 的 k 个近邻。设这 N 个样本中来自 ω_1 类的样本有 N_1

个, 来自 ω_2 类的样本有 N_2 个, \dots , 来自 ω_c 类的有 N_c 个, 如果 k_1, k_2, \dots, k_c 分别是 k 个近邻中属于 $\omega_1, \omega_2, \dots, \omega_c$ 类的样本数, 则可以定义判别函数为:

$$g_i(x) = k_i, i = 1, 2, \dots, c \quad (15)$$

决策规则为: if $g_i(x) = \max k_i$ then $x \in \omega_j$ 。并采用如下的方法确定 k 的值:

For $k = 1, 2, \dots, N$

error(k) = 0;

- 1) 随机地选取一个测试数据隐藏其类别标签。
- 2) 根据剩余的数据和给定的 k , 预测被取走的样本数据的类别标签。
- 3) 如果预测结果与真正的分类标签不同, 则 error(k) = error(k) + 1。重复该过程直到所有的训练样本都被测试。

选择一个 error(k) 最小的 k 。

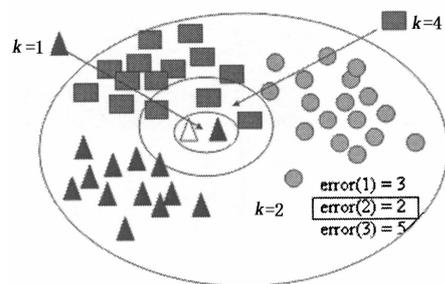


图 1 留一交互验证示意图

Fig. 1 leave-one-out cross validation diagram

5 实验结果与分析

为验证上文讨论的方法, 我们采用 Ohio 州立大学的可见/红外人脸数据库, 该人脸库包含 29 个不同性别的红外和可见人脸图像, 且具有不同的表情、人脸姿态和光照。本文进行了两组实验, 在试验中, 选择了其中的 6 人, 每一个人有 88 对红外/可见图像, 把红外和可见图像转换为 60×60 的 8-bit 灰度人脸图像, 在第一组实验中采用了留一交互验证的方法, 以验证 KCCA 融合识别算法的性能, 并把我们的算法与已有的 2DCCA 和 PCA-CCA 特征融合识别算法进行了比较。在第二组实验中, 把图像库分为训练集和测试集两部分, 以测试算法对表情和光照的抗干扰能力, 如图 2 和图 3 所示。其中, 训练集为 6 人每人 66 个样本共 396 个样本, 测试集为 6 人, 光照条件有均匀加亮 50 个灰度级, 均匀减暗 50 个灰度级, 光照不均匀 (光照不均匀的情况见图 3 所示) 三种情况, 表情有高兴和苦闷两种情况, 每人在每种情况下的样本分别为 11 个共 66 个样本。

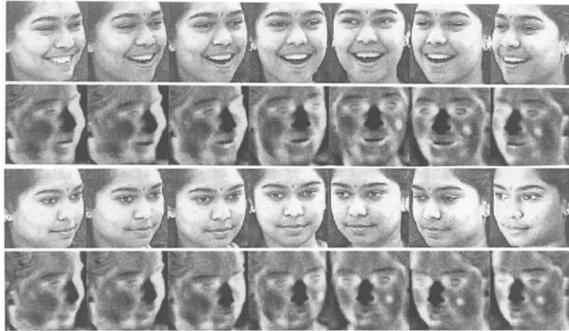


图 2 Priya 的两种表情部分红外/可见图像

Fig. 2 balage's thermal/visible face image with two expressions



图 3 Priya 的两种光照条件下的部分红外/可见图像

Fig. 3 priya's thermal/visible face image with two illuminations

在第一组实验中,使用了留一交互迭代 (LOOCV)对现有的几种典型相关分析方法的分类正确率进行了比较。这里首先对已有的二维典型相关分析(2DCCA)和 PCA + CCA 的目标识别方法原理进行简单的介绍。2DCCA 直接利用图像的矩阵表达形式进行相关投影分析,设样本集中有 N 对图像,它首先计算出各自的均值,然后直接确定投影方向,由于

这种方法无需把图像矩阵转化为高维向量,所以极大地提高了特征的抽取速度。而 PCA + CCA 的目标识别方法首先利用 PCA 分别进行高维原始样本的维数约简,然后在变换后的特征空间中利用第 2.1 节所述的方法进行特征提取。从图 4 和表 1 中可以看出,PCA + CCA 的分类正确率在维数为 20 以上时才能达到 80%,而 2DCCA 和 KCCA 的识别性能明显优于 PCA + CCA。当然,从表 2 和表 3 中可以看出,KCCA 的分类性能随选取的核函数的不同会有一些差异,如在表情变化条件下采用指数形式的核函数的 KCCA 的分类正确率明显由于 2DCCA,双曲正切形式的核函数的 KCCA 的分类正确率的优势则并不显著;而在光照变化条件下,指数形式的 KCCA 的分类正确率则并不尽如人意,这需要在实际应用中随着分类对象的不同通过实验进行调整。

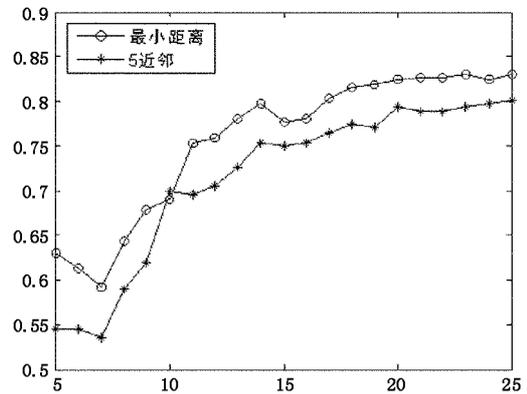


图 4 PCA + CCA 的识别正确率

Fig. 4 the recognition accuracy using PCA + CCA

表 1 留一法 KCCA 与 2DCCA 的错分数比较(总测试样本数 528)

Tab. 1 Comparison of recognition Accuracy using KCCA and 2DCCA

特征维数	1	2	3	4	5	6	7	8	9	10	核函数类型
2DCCA 错分样本数	10	7	8	9	7	6	3	4	4	4	
KCCA 错分样本数	3	1	3	1	3	1	1	2	2	3	指数 1
	4	8	6	8	4	4	3	5	3	2	指数 16
	3	5	7	3	6	5	5	4	4	5	指数 256
	9	5	6	5	5	5	4	4	5	3	双曲正切

表 2 KCCA 与 2DCCA 在光照变化下的错分数量比较(总测试样本数 66)

Tab. 2 The Comparison of recognition Accuracy using KCCA and 2DCCA under illumination variance

Dimensionality	1	2	3	4	5	6	7	8	9	10	核函数
KCCA 错分样本数	22	44	40	37	22	13	10	7	7	4	指数形式
	5	12	18	16	20	14	13	6	4	4	双曲正切
2DCCA	15	12	20	18	18	18	15	10	7	6	

表3 KCCA 与 2DCCA 在表情变化下的错分数量比较(总测试样本数 66)

Tab.3 The Comparison of recognition Accuracy using KCCA and 2DCCA under expression variance

Dimensionality	1	2	3	4	5	6	7	8	9	10	表情变化	核函数
KCCA	11	9	8	8	8	8	7	6	7	5	喜悦表情	双曲正切
错分样本数	4	0	1	0	0	0	0	0	0	0		指数形式
2DCCA	13	5	9	9	9	9	8	8	8	8		
KCCA	9	5	4	4	1	3	2	2	2	1	苦闷表情	双曲正切
错分样本数	5	0	0	0	0	0	0	0	0	0		指数形式
2DCCA	9	7	5	5	3	3	3	3	3	3		

6 结 论

典型相关分析的方法已经广泛应用于统计分析、盲源分离和模式识别的各个领域。本文研究了基于核函数的典型相关分析的基本原理,提出了一种基于核函数的典型相关分析的融合人脸识别算法。我们提出的算法为特征级图像融合提出了一个继续努力的工作方向,下一步的工作是从理论上进一步完善算法,找出核函数在独立分量分析(ICA)、主成分分析(PCA)和典型相关分析(CCA)等不同的数学分析方法中的内在联系,为拓宽基于核函数的图像分析方法提供更坚实的理论指导。

参考文献:

[1] T K Kim, Sh F Wong, R Cipolla. Tensor canonical correlation analysis for action classification[C]. IEEE Computer Vision and Pattern Recognition, 2007. CVPR'07.
 [2] J Via, I Santamaria, J Perez. Canonical correlation analysis (CCA) algorithms multiple data sets; application to blind simo equalization [J]. Neural Networks, 2007, 20 (1): 139 - 152.
 [3] Cannon A J, Hsieh W W. Robust nonlinear canonical corre-

lation analysis; application to seasonal climate forecasting, Nonlin[J]. Processes Geophys., 2008, 15 :221 - 232.
 [4] J J Verbeek, S T Roweis, N Vlassis. Non-linear CCA and PCA by alignment of local models[J]. Neural Information Processing Systems NIPS', 2003, 16 :297 - 304.
 [5] 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 : 1524 - 1533.
 [6] L Sun, J Wang, J Ye. A least squares formulation for canonical correlation analysi[C]. Proceedings of the 25th International Conference on Machine Learning, Helsinki, Finland, 2008.
 [7] Akaho S. A kernel method for canonical correlation analysis[C]. International Meeting of Psychometric Society, 2001.
 [8] Melzer T, Reiter M, Bischof H. Appearance models based on kernel canonical correlation analysis[J]. Pattern Recognition, 2003, 36 (9) : 1961 - 197.
 [9] Gretton A, Herbrich R, Smola A, et al. Kernel methods for measuring independence [J]. J. Machine Learning Research, 2005, 6 :2075 - 2129.