

一种广义局部判别型典型相关分析算法

刘云东¹, 崔琳¹, 郝汝岗²

(1. 宿州学院信息工程学院, 安徽 宿州 234000; 2. 兰州理工大学计算机与通信学院, 兰州 730050)

摘要:在局部判别型典型相关分析(LDCCA)的基础上, 提出一种广义局部判别型典型相关分析算法(GLDCCA)。该算法在准则函数的内协方差矩阵中引入样本类别信息, 使其提取的特征更有利于模式分类, 采用核主成份分析解决小样本问题, 克服传统 PCA 所受到的线性约束。在人工数据集以及 ORL 和 Yale 2 个人脸库上进行实验, 结果表明, 与 CCA 算法和 LDCCA 算法相比, GLDCCA 算法具有更高的识别性能。

关键词:人脸识别; 鉴别信息; 典型相关分析; 特征维数; 特征融合; 内协方差矩阵

Generalized Locality Discriminative Canonical Correlation Analysis Algorithm

LIU Yun-dong¹, CUI Lin¹, HAO Ru-gang²

(1. School of Information Engineering, Suzhou University, Suzhou 234000, China;

2. School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

【Abstract】 On the basis of the Locality Discriminative Canonical Correlation Analysis(LDCCA), this paper proposes a new supervised learning algorithm called Generalized Locality Discriminative Canonical Correlation Analysis(GLDCCA) algorithm, which can utilize much effectively the class information of samples in the covariance matrix. Meanwhile, Kernel Principal Component Analysis(KPCA) is used to solve the small sample problem and avoid the linear constraint which PCA is subjected to. Experimental results on artificial data sets, facial database including ORL and Yale show that the proposed GLDCCA algorithm is superior to CCA, LDCCA in recognition performance.

【Key words】 face recognition; discriminative information; Canonical Correlation Analysis(CCA); feature dimension; feature fusion; within covariance matrix

DOI: 10.3969/j.issn.1000-3428.2012.07.053

1 概述

随着计算机技术的发展, 信息融合技术成为一种新兴的数据处理技术。信息融合^[1-2]通常包括分数级、特征级、决策级 3 个层次, 其中, 特征级融合利用的原始信息最多, 从理论上可以获得最好的性能, 但传统的基于特征级的串行特征融合^[3]与并行特征融合^[4]方法容易引起“维数灾难”问题, 并且存在大量的信息冗余。为此, 文献[5]提出了一种基于典型相关分析(Canonical Correlation Analysis, CCA)的特征融合方法, 克服了串行融合和并行融合的不足。但该方法没有利用样本的类别信息, 其提取的特征未必有利于分类。因此, 文献[6]进一步提出广义典型相关分析(Generalized CCA, GCCA)方法, 把类别信息引入到准则函数中, 使分类性能有所提高。

大量的研究实验表明: 人脸图像分布在一个非线性流形结构上。虽然 CCA、GCCA 等算法可以很好地解决线性问题, 但当面对人脸识别中的非线性问题时, 则会出现欠学习现象。为了解决这一问题, 文献[7]结合局部化思想提出了一种局部判别型典型相关分析方法(Locality Discriminative CCA, LDCCA), 该方法可以保留样本间的局部相似结构信息, 同时能够实现同类样本相关最大化与异类样本相关最小化。然而其准则函数中的内协方差矩阵没有利用样本的类别信息, 当光照、表情、姿态等因素发生较大的变化时, 会导致识别性能的下降。

针对 LDCCA 的不足, 本文提出了一种广义局部判别型

典型相关分析方法(GLDCCA)。通过把类别信息引入到准则函数的内协方差矩阵中, 使其提取的特征更加具有鉴别力。

2 局部判别型典型相关分析算法

对于给定的 n 对样本 $\{(x_i, y_i)\}_{i=1}^n$, $x_i \in R^p$, $y_i \in R^q$, LDCCA 的目标是寻找一组投影轴 w_x 、 w_y , 使抽取的同类 k 近邻样本特征间的相关性最大化, 同时使不同类 k 近邻样本特征间的相关性最小化, 其判决准则函数如下:

$$J = \frac{w_x^T s_{xy} w_y}{\sqrt{w_x^T s_{xx} w_x \times w_y^T s_{yy} w_y}} \quad (1)$$

其中, $s_{xy} = s_w - \eta s_b$, s_w 、 s_b 分别是局部类内相关矩阵与局部类间相关矩阵; s_{xx} 、 s_{yy} 分别是样本集合 X 、 Y 的内协方差矩阵, 其中:

$$s_w = \sum_{i=1}^n \sum_{x_i \in N^l(x_j) \cap y_j \in N^l(y_i)} x_i y_i^T + x_k y_i^T \quad (2)$$

$$s_b = \sum_{i=1}^n \sum_{x_i \in N^l(x_j) \cap y_j \in N^l(y_i)} x_i y_k^T + x_k y_i^T \quad (3)$$

基金项目:安徽省高校优秀青年人才基金资助项目(2009SQRZ171, 2010SQRL192); 安徽省教育厅自然科学基金资助项目(KJ2009B121); 安徽省高校省级自然科学基金资助项目(KJ2012Z395)

作者简介:刘云东(1979-), 男, 讲师、硕士, 主研方向: 信息处理; 崔琳, 讲师、硕士; 郝汝岗, 硕士

收稿日期: 2011-08-15 **E-mail:** szxyld@126.com

$$s_{xx} = XX^T \tag{4}$$

$$s_{yy} = YY^T \tag{5}$$

其中, $N^l(i)$ 表示 x_i 的类内 k 邻域, 即同类中与 x_i 最相似的样本点集合, $N^o(i)$ 表示 x_i 的类间 k 邻域, 即异类中与 x_i 最相似的样本点集合。使准则函数式(1)达到最大化的 w_x 、 w_y 即为最优投影轴, 具体求解过程参考文献[8]。

3 GLDCCA 在人脸识别中的应用

3.1 GLDCCA 基本思想

LDCCA 通过最大化准则函数达到求解最优投影轴的目的。通过分析可知, 式(1)分子部分的极大化, 其直观意义是: 使 k 近邻样本特征间的相关性达到最大, 同时使异类 k 近邻样本特征间的相关性最小, 而分母的极小化则缺乏实际的物理意义。为此, 给出 s_{xx} 、 s_{yy} 另外一种定义形式, 提出一种广义局部判别典型相关分析算法(GLDCCA)。令:

$$s_{xx} = s_w^x - s_b^x, \quad s_{yy} = s_w^y - s_b^y$$

其中:

$$s_b^x = \sum_{i=1}^C p(w_i)(m_i^x - m^x)(m_i^x - m^x)^T \tag{8}$$

$$s_b^y = \sum_{i=1}^C p(w_i)(m_i^y - m^y)(m_i^y - m^y)^T \tag{9}$$

$$s_w^x = \sum_{i=1}^C p(w_i) \left\{ \sum_{j=1}^{N_i} \frac{1}{N_i} (x_{ij} - m_i^x)(x_{ij} - m_i^x)^T \right\} \tag{10}$$

$$s_w^y = \sum_{i=1}^C p(w_i) \left\{ \sum_{j=1}^{N_i} \frac{1}{N_i} (y_{ij} - m_i^y)(y_{ij} - m_i^y)^T \right\} \tag{11}$$

其中, s_w^x 、 s_b^x 分别表示训练样本 X 的类内散布矩阵与类间散布矩阵; s_w^y 、 s_b^y 分别表示训练样本 Y 的类内散布矩阵与类间散布矩阵; $x_{ij} \in X$, $y_{ij} \in Y$ 分别表示样本集合 X 、 Y 的第 i 类第 j 个训练样本的 2 个特征矢量; C 表示类别数; $p(w_i)$ 表示第 i 类样本的先验概率; N_i 表示第 i 类训练样本数; m_i^x 、 m_i^y 分别表示 X 、 Y 的第 i 类训练样本平均向量; m^x 、 m^y 分别表示样本集合 X 与 Y 的平均向量。

在 GLDCCA 中, 通过把类别信息引入到 s_{xx} 、 s_{yy} , 不仅使其提取的同类 k 近邻特征相关性达到最大, 异类 k 近邻特征相关性最小, 而且可以使同类样本点在投影空间相距比较近, 异类样本点在投影空间相距比较远, 从而更加充分有效地保持了样本的鉴别信息。

求解过程参照典型相关分析算法[6], 得:

$$\begin{cases} S_{xy} S_{yy}^{-1} S_{yx} W_x = \lambda^2 S_{xx} W_x \\ S_{yx} S_{xx}^{-1} S_{xy} W_y = \lambda^2 S_{yy} W_y \end{cases} \tag{12}$$

令 $M_{xx} = S_{xx}^{-1} S_{xy} S_{yy}^{-1} S_{yx}$, $M_{yy} = S_{yy}^{-1} S_{yx} S_{xx}^{-1} S_{xy}$, 得:

$$\begin{cases} M_{xx} W_x = \lambda^2 W_x \\ M_{yy} W_y = \lambda^2 W_y \end{cases} \tag{13}$$

求解上述特征值问题, 取前 d 对最大本征值对应的本征向量组成投影轴, 得 $w_x = (\alpha_1, \alpha_2, \dots, \alpha_d)$, $w_y = (\beta_1, \beta_2, \dots, \beta_d)$ 对于一对样本 (x, y) , 采用如下方式进行融合:

$$W_x^T x + W_y^T y \tag{14}$$

$$\begin{cases} W_x^T x \\ W_y^T y \end{cases} \tag{15}$$

式(14)、式(15)分别称为并行方式与串行方式, 最后采用融合特征进行人脸识别。

为解决 GLDCCA 遇到的小样本问题, 采用核主成份分

析^[8](KPCA)将用于融合的 2 组特征矢量 X 、 Y 进行降维处理, 克服了传统的 PCA 在解决小样本问题时所受到的线性约束。

3.2 基于 GLDCCA 的人脸特征融合

本文把 GLDCCA 方法应用于人脸特征融合, 将得到的相关性特征用于分类。具体步骤如下:

Step1 在原始人脸图像集中选取 n 幅图像作为第 1 组训练样本空间 $X = \{x | x \in R^p\}$, 利用小波包对第 1 组训练样本图像进行 3 次小波变换, 取低频图像构成第 2 组训练样本空间 $Y = \{y | y \in R^q\}$ 。

Step2 通过 KPCA 将用于融合的 2 组样本图像集合 X 、 Y 分别进行降维处理, 得到 X' 、 Y' 。

Step3 在 X' 、 Y' 上计算 s_{xx} 、 s_{yy} 、 s_{xy} 、 s_{yx} 进而求出 M_{xx} 、 M_{yy} 。

Step4 分别求解 M_{xx} 、 M_{yy} 的本征值, 并求解出相应的本征向量。

Step5 取前 d 对最大本征值对应的本征向量构成变换矩阵 w_x 、 w_y , 进而求得 2 组相关投影特征向量 $F_x = w_x^T X'$, $F_y = w_y^T Y'$, 采用式(14)、式(15)进行特征融合。

Step6 对于一个待测样本 x , 按照上述过程得到其融合特征 F , 最后采用最近邻分类器进行分类。

4 仿真实验与结果分析

为了验证 GLDCCA 方法的有效性, 采用人工数据集及 ORL 与 Yale2 个著名的人脸数据库进行实验, 作为对比, 还实现了 CCA、LDCCA 2 种方法, 实验采用 Matlab7.0 编程实现, 所有方法均采用最近邻分类器进行分类。

4.1 人工数据集上的测试结果

对于一个包含 60 对二维样本的数据集 $\{x_i, y_i\}_{i=1}^{60}$, x_i^k 、 y_i^k 分别表示第 $k(k=1,2)$ 类样本。 x_i^k 均满足高斯分布 $N(\mu_k, \eta_k)$, 其中, $\mu_1 = [9.2, 1.3]^T$; $\eta_1 = \begin{bmatrix} 12 & 2.5 \\ 2.5 & 12 \end{bmatrix}$; $\mu_2 = [6.4, -5.2]^T$; $\eta_2 = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}$; $y_i^k = w^T x_i^k + \varepsilon_i^k$; $w = \begin{bmatrix} 0.5 & 0.2 \\ 0.7 & 0.1 \end{bmatrix}$; ε_i^k 为添加的高斯噪声。分别采用 CCA、LDCCA、GLDCCA 3 种方法对数据集进行处理, 观察提取的第 1 对特征 $(w_x^T x, w_y^T y)$ 在特征空间的分布情况。

由图 1~图 4 可知, CCA 提取的特征之间具有一种线性关系, 并且 2 类特征存在严重的重叠现象。LDCCA 提取的 2 类特征存在部分重叠, 而 GLDCCA 提取的 2 类特征在特征空间被较好地分开, 这更加有利于模式分类。




图 1 2 类数据分布




图2 CCA提取的第1对特征分布




图3 LDCCA提取的第2对特征分布




图4 GLDCCA提取的第1对特征分布

4.2 Yale人脸库上的测试结果

Yale人脸库是由耶鲁大学创建,由5个人每人11幅人脸图像(正面光照、左面光照、右面光照、戴眼镜、不戴眼镜、高兴、正常、伤心、欲睡、惊奇和眨眼)共165张多表情、多光照的图像组成,且每张图像大小为112×92像素,所有图像均是在严格控制表情和光照变化的条件下采集的。为便于计算,将人脸图像裁剪为46×38像素,Yale人脸库中2个人的部分图像如图5所示。



图5 Yale数据库部分人脸图像

在Yale人脸库的15个人中随机取出每人的6张图像作为训练集,其余的作为测试集。随机实验独立进行10次,实

验采用式(14)、式(15)这2种特征融合方式,记录其平均识别率作为最终的测试结果。其中,CCA、LDCCA均采用PCA对样本数据进行降维处理,实验结果见表1、图6、图7所示。

表1 不同近邻数(k)和特征维数(n)下的最高平均识别率

方法	式(14)融合方式	k/n	式(15)融合方式	k/n
CCA	0.853 3	/19	0.853 3	/38
LDCCA	0.946 7	3/15	0.948 2	5/32
GLDCCA	0.960 0	4/12	0.973 3	7/25




图6 取k=15采用式(14)融合方式时的平均识别率

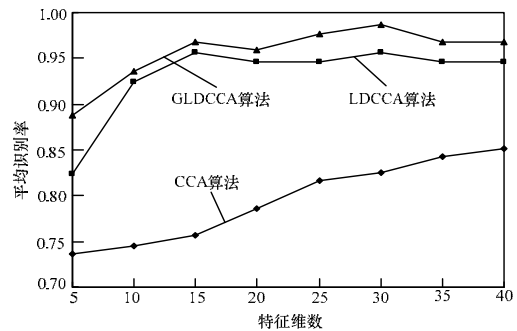


图7 取k=10采用式(15)融合方式时的平均识别率

由图6、图7可知,对于特征维数不同的情况,GLDCCA在FFS1和FFS2这2种特征融合方式下的平均识别率均高于CCA、LDCCA。表1实验数据表明,在FFS1融合方式下,GLDCCA的最高平均识别率高出LDCCA将近2个百分点,在FFS2方式下提高将近3个百分点。可见,相比LDCCA,GLDCCA提取的组合特征具有较强的分类能力,对光照和表情的变化具有一定的不敏感性。

4.3 ORL人脸库上的测试结果

ORL人脸库由英国剑桥大学创建,含40个人共400张灰度图像,每个人有10张不同的人脸图像,且每张图像大小为112×92像素,其中有些图像拍摄于不同时期。人脸姿态有相当程度的变化,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。为了降低计算复杂度,将图像裁剪为46×38。ORL人脸库部分人脸如图8所示。



图8 ORL人脸库部分图像

在ORL人脸数据集上,随机选取每人的5张图像作训练,其余5张作测试。表2记录了各种方法在不同近邻数与不同的特征维数下的识别结果。(下转第167页)

对以上实验结果进行分析可得出如下结论: 在 DE 算法中引入拉马克进化和鲍德温效应 2 种局部搜索机制, 求解质量及收敛速度都有明显改善。而且在较大规模背包问题求解中, 本文算法仍取得良好的求解效果, 对于 KP4, 本文得到了新的最优解 30 085。

综上所述, LBHDE 算法在求解背包问题时优势明显。原因是 DE 算法的全局搜索能力很强, 而局部搜索能力相对较弱。拉马克进化和鲍德温效应是 2 种局部搜索机制, 其搜索是在表现型空间进行的。其中, 拉马克进化使搜索到的优良个体直接进入群体, 对于小范围生成新个体而言, 直接在表现型空间进行局部搜索优于在基因型空间进行交叉和变异操作。所以, 拉马克进化的引入通常能够提高算法的收敛速度, 减少进化代数。而鲍德温效应能够使自然适应度小的个体得到一个较大的学习适应度值, 从而增大了该个体在下一代选择操作中被选中的概率, 增强了群体的多样性。因此, 在 DE 算法中融入拉马克进化和鲍德温效应, 充分利用 2 种搜索对种群的不同影响, 在提高求解质量的同时, 算法具有更好的求解效率。

5 结束语

本文从改善差异演化算法局部搜索能力及提高其在离散优化问题中的求解效率出发, 提出了用于求解 0/1 背包问题的拉马克-鲍德温混合差异演化算法 LBHDE。实验表明, 该算法在求解各种规模的背包问题时, 是一种高效可行的方法。下一步将研究拉马克进化和鲍德温效应的局部搜索实现方法, 进一步提高算法的效率。

参考文献

- [1] Dantzig G B. Discrete Variable Extremum Problems[J]. Operations Research, 1957, 5(2): 266-277.
- [2] 于 惠. 遗传算法的改进研究及在背包问题中的应用[D]. 济南: 山东大学, 2009.
- [3] Horowitz E, Sahni S. Computing Partitions with Applications to Knapsack Problem[J]. Journal of ACM, 1974, 21(2): 277-292.
- [4] Pisinger D. Linear Time Algorithm for Knapsack Problem with

- Bounded Weights[J]. Journal of Algorithms, 1999, 33(1): 1-14.
- [5] 罗小虎, 吕 强, 钱培德. 一类难解 0/1 背包问题的有效搜索算法[J]. 计算机工程, 2010, 36(17): 195-197.
- [6] 霍红卫, 许 进, 保 铮. 基于遗传算法的 0/1 背包问题求解[J]. 西安电子科技大学学报, 1999, 26(4): 493-497.
- [7] 马丰宁, 谢 龙, 郑 重. 求解背包问题的基因属性保留遗传算法[J]. 天津大学学报, 2010, 43(11): 1020-1024.
- [8] 许小勇. 基于改进的模拟退火算法求解 0/1 背包问题[J]. 海南大学学报: 自然科学版, 2008, 26(4): 356-358.
- [9] 沈显君, 王伟武, 郑波尽, 等. 基于改进的微粒群优化算法的 0-1 背包问题求解[J]. 计算机工程, 2006, 32(18): 23-25, 38.
- [10] 张其亮, 陈永生. 基于模拟退火思想改进的粒子群算法求解背包问题[J]. 现代电子技术, 2010, 26(2): 85-89.
- [11] Storn R, Price K. Differential Evolution: A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces[D]. Berkeley, USA: University of California, 2002.
- [12] 蔡鸿英, 郝志峰, 王志刚, 等. 解 0-1 背包问题的二进制差异演化算法[J]. 计算机工程与设计, 2009, 30(7): 1716-1721.
- [13] 苗世清, 高岳林. 求解 0/1 背包问题的离散差分进化算法[J]. 小型微型计算机系统, 2009, 30(9): 1828-1830.
- [14] 邓长寿, 赵秉岩, 梁昌勇. 混合二进制差异演化算法解 0-1 背包问题[J]. 计算机工程与设计, 2010, 32(8): 1795-1797.
- [15] 拉马克. 动物哲学[M]. 北京: 商务印书馆, 1936.
- [16] Turney P, Whitley D, Anderson R. Evolution, Learning, and Instinct: 100 Years of the Baldwin Effect[J]. Evolutionary Computation Archive, 1996, 4(3): 55-63.
- [17] Whitley D, Gordon V S, Mathias K. Lamarckian Evolution, the Baldwin Effect and Function Optimization[M]// Ackley D, Littman M. Parallel Problem Solving from Nature. Berlin, Germany: Springer-Verlag, 1994.
- [18] 张家奇, 陈启军. 学习对进化的影响研究及仿真验证[J]. 系统仿真学报, 2007, 19(24): 5849-5855.
- [19] 夏柱昌, 刘 芳, 公茂果, 等. 基于记忆库拉马克进化算法的作业车间调度[J]. 软件学报, 2010, 21(12): 3082-3093.

编辑 张正兴

(上接第 163 页)

表 2 ORL 数据集上的最高平均识别率

方法	式(14)融合方式	k/n	式(15)融合方式	k/n
CCA	0.903 1	/22	0.905	/44
LDCCA	0.945 0	7/19	0.950	4/36
GLDCCA	0.965 0	3/15	0.990	5/28

由表 2 可见, GLDCCA 在较低的特征维数下, 仍然取得了优于 CCA、LDCCA 的识别效果。实验结果表明, GLDCCA 对姿态的变化也具有较好的鲁棒性。

5 结束语

本文提出的广义局部判别典型相关分析方法(GLDCCA)通过将样本类别信息引入到内协方差矩阵, 在保持 LDCCA 特性的同时, 可以使同类样本点在投影空间相距比较近, 异类样本点在投影空间相距比较远, 从而更加充分有效地保持样本的鉴别信息。在人工数据集、Yale 和 ORL 人脸库上验证了 GLDCCA 方法的有效性。然而, 近邻数 k 的选择仍然是通过实验手段得到的, 尚缺乏一定的理论指导, 如何快速有效地选择最佳的 k 值是下一步要进行的研究工作。

参考文献

- [1] Wu Jiying, An Gaoyun, Ruan Qiuqi. Independent Gabor Analysis of Discriminant Features Fusion for Face Recognition[J]. Signal

Processing Letters, 2009, 16(2): 97-100.

- [2] Sun Bingyu, Zhang Xiaoming, Li Jiuyong, et al. Feature Fusion Using Locally Linear Embedding for Classification[J]. IEEE Transactions on Neural Networks, 2010, 21(1): 163-168.
- [3] Yang Jian, Yang Jingyu, Zhang D. Feature Fusion: Parallel Strategy vs. Serial Strategy[J]. Pattern Recognition, 2003, 36(6): 1369-1381.
- [4] Li Junbao, Chu Shuchuan, Yang J S P. Discriminant Pattern Classification[J]. Journal of Digital Information Management, 2008, 6(2): 203-207.
- [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(9): 1524-1533.
- [6] Sun Quanshen, Heng P A, Jin Zhong, et al. Face Recognition Based on Generalized Canonical Correlation Analysis[C]// Proceedings of International Conference on Intelligent Computing. Hefei, China: Springer, 2005: 958-967.
- [7] 彭 岩, 张道强. 局部判别型典型相关分析算法[J]. 计算机工程与应用, 2008, 44(21): 126-129.
- [8] 郭 飞, 王 成. 基于 LMP 和 KPCA 的人脸识别[J]. 计算机工程, 2010, 36(24): 183-185.

编辑 索书志