

KPCA 和 NS-LDA 相结合的人脸识别研究

董吉文,赵磊,李秀丽

(济南大学 信息科学与工程学院,山东 济南 250022;
山东省网络环境智能计算技术重点实验室,山东 济南 250022)

摘要:为了能够通过保留类内散布矩阵零空间的有效鉴别信息,并选择恰当的投影找到最大可能地区别类内类间的数据集,文章分别选用核主成分分析(KPCA)和零空间线性鉴别分析(null space LDA),其中核主成分分析(KPCA)是主成分分析(PCA)在核空间中的非线性推广,零空间线性鉴别分析利用了零空间的有效信息。文中将 KPCA 和 NS-LDA 的特征提取方法结合并应用于人脸识别研究,其综合了 KPCA 利用数据高阶性和经 NS-LDA 投影矩阵良好可分性的优点来增强人脸识别性能。实验结果证明,该方法能够有效地提高人脸识别率。

关键词:核主成分分析;零空间线性鉴别分析;人脸识别;余弦角距离

中图分类号:TP391.41

文献标识码:A

文章编号:1673-629X(2013)05-0100-04

doi:10.3969/j.issn.1673-629X.2013.05.026

Research on Face Recognition Combined KPCA and NS-LDA

DONG Ji-wen, ZHAO Lei, LI Xiu-li

(College of Information Science and Engineering, University of Jinan, Jinan 250022, China;
Shandong Provincial Key Laboratory of Network Based Intelligent Computing, Jinan 250022, China)

Abstract: In order to retain the effective identification information of scattering matrix zero space inside the class, select the appropriate projection to maximize finding the data set inside and between classes, respectively choose Kernel Principal Component Analysis (KPCA) and Null Space Linear Discrimination Analysis (NS-LDA), the KPCA is the nonlinear promotion of PCA in the kernel space, NS-LDA takes advantage of zero space information effectively. The feature extraction method of the KPCA and NS-LDA is combined and applied to face recognition research, it combines the advantage of KPCA using data and NS-LDA good separability of projection matrix to enhance face recognition performance. The experimental results show that the method can effectively improve the face recognition rate.

Key words: KPCA; NS-LDA; face recognition; cosine angle distance

0 引言

人脸识别研究是图形图像和模式识别领域中的热点研究方向之一,相比视网膜、指纹识别技术又有着方便、快捷的优势,在身份识别、监控系统等方面有着广泛的应用前景和市场,同时也与生物信息学、生理学、解剖学等多学科联系紧密。近几年,人脸识别技术得到了飞速的发展,其中特征脸(Eigenfaces)方法^[1]及 Fisher(Fisherfaces)脸方法^[2,3]是最为著名的两种。特征脸法是通过主成分分析(PCA)^[4]重构具有最小均方误差意义下的特征脸来进行人脸识别,而 Fisher 脸是通过线性鉴别分析求解一组特征矢量来识别人脸,

PCA 和 LDA^[3,5]在一定程度上是互补的,但两者都是基于线性特征的提取方法^[6,7],实际中人脸往往由于光照、表情、视角等因素造成极端的非线性特性,文中利用核函数方法^[8,9]将原始数据嵌入到高维空间^[10],然后用 PCA 对核空间^[11,12]中的数据集进行降维,接着在降维的空间中使用改进 LDA^[13,14]。在最近邻算法中,样本数据之间的邻近性一般用欧式距离和余弦角距离^[15]来表示,前者对于稀疏数据比较敏感,而后者对于稀疏数据有着良好的健壮性,在人脸识别实验中,余弦角距离比欧氏距离更符合表达数据之间的邻近性。

1 KPCA

KPCA 实际上是核空间中的 PCA,只不过计算过程被巧妙地用核函数替代而已,但它高效地实现了算法的非线性。设人脸图像为按列排成的长度为 N 的矩阵 $\{R_i | i = 1, 2, \dots, N\}$,非线性映射函数 η 将每一列

收稿日期:2012-08-31;修回日期:2012-12-03

基金项目:山东省自然科学基金(ZR2010FL006)

作者简介:董吉文(1964-),男,山东莱州人,教授,主要研究方向为图像处理、数据库;赵磊(1988-),男,山东威海人,硕士研究生,主要研究方向为图像处理、模式识别。

映射到特征空间 F 中, $\eta \rightarrow F$, 特征空间样本为 $\mathbf{k}(x_1), \mathbf{k}(x_2), \dots, \mathbf{k}(x_N)$ 。

令 $\mathbf{K}(X) = [\mathbf{k}(x_1), \mathbf{k}(x_2), \dots, \mathbf{k}(x_N)]$, 在特征空间 F 中核矩阵 $\mathbf{K}(X)$ 的协方差矩阵为:

$$\mathbf{G}_k = \frac{1}{N} \sum_{j=1}^N (\mathbf{k}(x_j) - \mathbf{m}_0^k) (\mathbf{k}(x_j) - \mathbf{m}_0^k)^T \quad (1)$$

其中 $\mathbf{m}_0^k = \frac{1}{N} \sum_{j=1}^N \mathbf{k}(x_j)$, 设 \mathbf{G}_k 的特征值 λ 和对应的特征向量 $\mathbf{V} \in F$, 即:

$$\mathbf{G}_k \mathbf{V} = \lambda \mathbf{V} \quad (2)$$

根据再生核理论, 空间 F 上对应的特征向量 \mathbf{V} 可以由 $\mathbf{k}(x_1), \mathbf{k}(x_2), \dots, \mathbf{k}(x_N)$ 线性表示, 即:

$$\mathbf{V} = a_i \sum_{j=1}^N \mathbf{k}(x_j) = \mathbf{K} \mathbf{a} \quad (3)$$

其中 $a_i (i = 1, 2, \dots, N)$ 是常数, 定义 $N \times N$ 的矩阵:

$$\mathbf{K}'(i, j) = \mathbf{k}(x_i)^T \mathbf{k}(x_j) \quad (4)$$

$\mathbf{K}'(i, j)$ 称为核矩阵, 将式(2)和式(3)结合得:

$$\mathbf{K}' \mathbf{a} = N \lambda \mathbf{a} \quad (5)$$

所以求解特征向量 \mathbf{V} 需要分解核矩阵 \mathbf{K}' 。

设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k > 0 (k \leq N)$ 为式(5)的前 k 个非零特征值, 对应特征向量为 $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_k$, 则由式(3)可解得特征空间 F 中的特征向量 $\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_k$ 的表达式。

另外, 归一化特征向量在一定程度上提高最终识别率, 将映射的核矩阵归一化, 即:

$$\mathbf{K}' = \mathbf{K}' - \mathbf{I}_N \mathbf{K}' - \mathbf{K}' \mathbf{I}_N + \mathbf{I}_N \mathbf{K}' \mathbf{I}_N \quad (6)$$

其中 $\mathbf{I}_{N(i, j)} = \frac{1}{N}$ 为 $N \times N$ 的矩阵, 则原始空间样本 x 在特征空间 F 中的第 k 个分量可表示为:

$$d_k(x) = \mathbf{a}_k^T \mathbf{K}'(i, x) (i = 1, 2, \dots, N) \quad (7)$$

其中 $\mathbf{K}'(i, x) = (\mathbf{K}'(x_1, x), \mathbf{K}'(x_2, x), \dots, \mathbf{K}'(x_N, x))^T$

$$\mathbf{K}'(i, x) = \mathbf{K}'(i, x) - \mathbf{K}'(i, x) \mathbf{I}_N - \mathbf{I}_N \mathbf{K}'(i, x) + \mathbf{I}_N \mathbf{K}'(i, x) \mathbf{I}_N$$

$$\mathbf{I}_N = \frac{1}{N} \left(\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N} \right)^T$$

目前常用核函数主要有三种:

(1) 多项式函数: $k(x, y) = (\langle x, y \rangle + \theta)^n$

(2) 径向基 RBF 函数 (高斯函数): $k(x, y) = \exp\left(-\frac{\|x - y\|^2}{c}\right)$

(3) Sigmoid 函数: $k(x, y) = \tanh(v \cdot \langle x, y \rangle + \theta)$

其中 v, c, θ 是核函数中的参数, $\tanh(\cdot)$ 是双曲正切函数, 不同核函数的选择和相应参数的调整对识别结果影响很大, 本实验选取的核函数是多项式函数,

其中在本实验多次选取核参数时验证, v 的选取在 $v \in (0, 1)$ 之间时提取的特征比在实数情况识别率好得多, 选取核参数 $\theta = 1, v = 0.7$ 时识别率最高。

2 NS-LDA

设人脸训练图像为 N 张, C 为人脸类别数目, N_i 为第 i 类的训练样本个数, LDA 的目的是尽可能地使类内离散度 \mathbf{S}_w 最小, 同时又使类间样本 \mathbf{S}_b 的距离最大, 二者可分别定义为:

$$\mathbf{S}_b = \sum_{i=1}^C p_i (\mathbf{u}_i - \mathbf{u}) (\mathbf{u}_i - \mathbf{u})^T \quad (8)$$

$$\mathbf{S}_w = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} (\mathbf{x}_i^j - \mathbf{u}_i) (\mathbf{x}_i^j - \mathbf{u}_i)^T \quad (9)$$

其中, $\mathbf{u}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{x}_i^j$ 为第 i 类人脸中的第 j 个样本向量, \mathbf{u} 是训练人脸样本总均值向量, 这时, 总体离散度矩阵可表示为:

$$\mathbf{S}_t = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \mathbf{u}) (\mathbf{x}_i - \mathbf{u})^T \quad (10)$$

即:

$$\mathbf{S}_t = \mathbf{S}_w + \mathbf{S}_b \quad (11)$$

传统的 FisherfaceLDA 是基于 Fisher 准则来寻求最佳投影矩阵 \mathbf{W} , 即最大化类间类内离散矩阵行列式的比值:

$$\mathbf{W} = \arg \max_{\mathbf{W}} J_F(\mathbf{W}) = \frac{|\mathbf{W}^T \mathbf{S}_b \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_w \mathbf{W}|} \quad (12)$$

但由于人脸图像是高度的非线性流体, 人脸的维数要远大于待识别人脸的张数 (即小样本问题), 所以传统的 LDA 严格的要求难以满足而导致识别率不高, 经过 KPCA+LDA 虽然缓解了小样本问题, 但是在避免小样本的同时舍弃了部分重要的类内散布矩阵零空间, 而事实上零空间内包含重要的分类信息。由于在总体散布矩阵的零空间正好是类间和类内散布矩阵零空间的交集, 去除总体散布矩阵的零空间不会影响识别信息的丢失并且达到了降维的目的, 然后在降维的空间里获取类内矩阵的零空间, 获取该零空间内类内矩阵的特征值和特征向量, 接着再获取其投影后的特征值和非零特征向量, 将以上获得特征向量组合成转换矩阵进行投影。具体的算法描述如下:

(1) 去掉总体散布矩阵 \mathbf{S}_t 的零空间: 对 \mathbf{S}_t 求取特征值和特征向量, \mathbf{U} 是非零特征值对应的特征向量, 将 \mathbf{S}_b 和 \mathbf{S}_w 分别向 \mathbf{U} 投影, 得到:

$$\mathbf{S}_b' = \mathbf{U}^T \mathbf{S}_b \mathbf{U} \quad (13)$$

$$\mathbf{S}_w' = \mathbf{U}^T \mathbf{S}_w \mathbf{U} \quad (14)$$

(2) 求 \mathbf{S}_w' 的特征值和特征向量, \mathbf{Q} 是零特征值对应的特征向量, 将 \mathbf{S}_b' 投影到 \mathbf{S}_w' 的零空间上,

$$S_b'' = Q^T S_w Q$$

(15)

(3) 去掉 S_b'' 的零空间,对 S_b'' 求特征值和特征向量, V 是非零特征值对应的特征向量。

(4) 转换以后的投影矩阵为 $W = UQV$, 训练样本和测试样本分别投影,送入分类器进行识别。

3 KPCA 和 NS-LDA 相结合的特征提取

传统的 LDA 和 PCA 拥有同样的缺陷,一是 LDA 本身是线性算法,数据中的非线性信息很难表达出来,二是 LDA 只涉及到数据信息的二阶统计性,不能表达数据的高阶统计特性,LDA 本身不仅计算量非常大,而且计算复杂,在通常情况下图像的维数往往会比特征训练样本个数大很多,给类内散布矩阵造成奇异困扰而使 LDA 算法求解困难,因此把 KPCA 和 NS-LDA 算法相融合来识别人脸。

KPCA 和 NS-LDA 算法的计算过程:

- (1) 采用 KPCA 算法得到人脸子空间。
- (2) 在 KPCA 的特征子空间中计算 NS-LDA 算法的特征子空间。

将训练和测试样本在上部分中得到的特征空间投影,从而得到识别特征,利用识别算法完成人脸鉴别。

除此之外,KPCA 将人脸样本映射到高维空间中,使其以较高概率线性可分,所以文中结合 KPCA 和类内散布矩阵零空间的有用分类信息找到令类间散度最大的分类投影方向,得到最优分类投影矩阵。

4 实验结果

实验采用包含在姿态、表情上有差异的 ORL 人脸数据库,原始人脸库包含 40 个人,每人 10 张总共 400 张图片,现将其用 Photoshop 从原始大小是 92×112 裁剪为 100×120 大小,256 灰度图像,位深度 8 位。

实验在不同数目的训练样本下比较人脸识别算法的识别率。从人脸库中每个人随机选取 5 ~ 7 张图片作为训练样本,见图 1。



图 1 ORL 库部分人脸图片

如表 1 所示,随着训练样本的增多,特征提取的有效信息越充分,相应的正确识别率就上升。基于特征脸的 KPCA 算法利用了高阶信息,但是其中包含的类别信息并不丰富,KPCA+NS-LDA 算法充分利用像素点之间的高阶信息,显著减少人脸表情、光照变化等高频干扰对特征的影响,提取到有利于识别的非线性特征,有效提高了正确识别率。

表 1 三种不同方法在 ORL 人脸库上的实验结果

算法	训练样本数	特征维数	识别率
KPCA	5	78	92.50%
	6	87	96.20%
	7	93	98.33%
KPCA+LDA	5	39	96.50%
	6	39	97.50%
	7	39	98.33%
KPCA+NS-LDA	5	39	97.50%
	6	39	98.12%
	7	39	98.33%

图 2 的实验是在训练样本为 5 时的结果,在选取的特征维数为 1 ~ 15 之间,识别率随特征维数变化波动较大,随着维数增加识别率略微波动但总体趋向稳定,三种算法的识别率都有极值点,KPCA 在维数为 78 时达到最大 92.50%,KPCA+LDA 在维数为 39 时达到最大 96.50%,KPCA+NS-LDA 在维数为 39 时达到最大 97.50%。总体来看,KPCA+NS-LDA 与 KPCA+LDA 算法的识别率相差不大,但略高于 KPCA 算法。局部来看,KPCA 在维数超过 30 维以后趋于稳定,且并不是随着特征数目越多,识别率就越高,这是因为特征中的非有利因素相应增多,并且,过多的特征提取增加识别过程的训练和识别时间,因此,文中使用的 KPCA+NS-LDA 算法使得识别达到较好效果。




图 2 不同算法对应识别率

(* KPCA, △ KPCA+LDA, + KPCA+NS-LDA)

表 2 是在训练样本为 5 时不同识别算法的识别率比较,在该实验数据中可以看出,作为最近邻分类器的余弦角距离方法的识别性能要优于欧氏距离下的识别性能,充分发挥了余弦角距离的优势。高维空间中,稀疏数据点比较多,孤立点对于距离计算的影响与原空间相比有所减弱,这时余弦角距离相比欧氏距离的优势也会有所减弱,这就使得应用欧氏距离的最近邻算

法的性能接近于应用余弦角距离的最近邻算法。

表2 两种分类器算法识别率比较

算法	欧式距离	余弦角距离
KPCA+LDA	93.5% (39)	96.5% (39)
KPCA+NS-LDA	97.5% (39)	97.5% (39)

5 结束语

文中提出 KPCA 和 NS-LDA 相结合的算法有效融合 KPCA 和 LDA 算法优点,充分利用人脸有效特征,利用核函数的非线性映射和 LDA 的二次特征提取,显著降低了有效特征的维数,通过提取零空间的有效信息,增强了特征向量的适应性和有效性,缓解了小样本问题,在最近邻分类器中选择性能较优的余弦角距离算法,得到较满意的人脸识别率。

参考文献:

[1] Turk M, Pentland A. Eigenfaces for Recognition[J]. Cognitive Neuro Science, 1991, 3(1): 71-86.

[2] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection[J]. IEEE Trans. on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.

[3] Yang M H. Kernel eigenfaces vs kernel fisherfaces: face recognition using kernel methods[C]//Proc of 5th IEEE Int Conf on Automatic Face and Gesture Recognition. Washington DC: [s. n.], 2002: 215-220.

[4] Chen Xin, Flynn P J, Bowyer K W. PCA-based Face Recognition in Infrared Imagery: Baseline and Comparative Studies [C]//Proc of the IEEE International Workshop on Analysis

and Modeling of Faces and Gestures. Nice, France: [s. n.], 2003: 127-134.

[5] Panda R, Naik M K. EBFS-Fisher: An Efficient Algorithm for LDA-based Face Recognition [C]//Proc of World Congress on Nature & Biologically Inspired Computing. Shantou, China: [s. n.], 2009: 1041-1046.

[6] Jin Jianming, Han Xionghu, Wang Qingren. Mathematical Formulas Extraction [C]//Proceedings of the 7th ICDAR. Edinburgh: [s. n.], 2003: 1138-1141.

[7] Jain A K, Duin R P W, Mao J C. Statistical pattern recognition: a review[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(1): 4-37.

[8] Müller K R, Mika S, Rätsch G, et al. An Introduction to Kernel-based Learning Algorithms[J]. IEEE Trans. on Neural Networks, 2001, 12(2): 181-201.

[9] 杜卓明, 屠宏, 耿国华. KPCA 方法过程研究与应用[J]. 计算机工程与应用, 2010, 46(7): 8-10.

[10] Yang Jian. KPCA Plus LDA: A Complete Kernel Fisher Discriminant Framework for Feature Extraction and Recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(2): 230-244.

[11] 朱美琳, 刘向东, 陈世福. 核方法在人脸识别中的应用[J]. 计算机科学, 2003, 30(5): 82-84.

[12] 时书剑, 马燕. 基于 Gabor 滤波和 KPCA 的人脸识别方法[J]. 计算机技术与发展, 2010, 20(4): 51-53.

[13] 何国辉, 甘俊英. PCA-LDA 算法在性别鉴别中的应用[J]. 计算机工程, 2006, 32(19): 208-210.

[14] 周晓彦, 郑文明. 一种融合 KPCA 和 KDA 的人脸识别新方法[J]. 计算机应用, 2008, 28(5): 1263-1266.

[15] 殷俊, 周静波, 金忠. 基于余弦角距离的主成分分析与核主成分分析[J]. 计算机工程与应用, 2011, 47(2): 9-12.

(上接第99页)

[3] 朱绍伟, 徐夫田, 滕兆明. 一种改进蚁群算法求解最短路径的应用[J]. 计算机技术与发展, 2011, 21(7): 76-78.

[4] 李宁宁, 刘玉树. 改进的 Dijkstra 算法在 GIS 路径规划中的应用[J]. 计算机与现代化, 2004, 9(2): 96-99.

[5] 陈述彭, 鲁爱军, 周成虎. 地理信息系统导论[M]. 北京: 科学出版社, 2000.

[6] Zhan F B. Three Fastest Shortest Path Algorithms on Real Road Networks[J]. Journal of Geographic Information and Decision Analysis, 1997, 1(1): 69-82.

[7] Viacheslav C, Mordechai S, Shmuel Z. On the performance of Dijkstra's third self-stabilizing algorithm for mutual exclusion [C]//Proc of 9th International Symposium on Stabilization, Safety and Security of Distributed Systems. [s. l.]: [s. n.], 2007: 114-123.

[8] Daniel C L. Proof of a modified Dijkstra's algorithm for compu-

ting shortest bundle delay in networks with deterministically time-varying links [J]. IEEE Communications Letters, 2006, 10(10): 734-736.

[9] Leonid K, Vladimir G, Zhao Jihui. Extending Dijkstra's algorithm to maximize the shortest path by node-wise limited arc interdiction [C]//Proc of First International Symposium on Computer Science - Theory and Applications. Russia: [s. n.], 2006: 221-234.

[10] 卢开澄, 卢华明. 图论及其应用[M]. 第2版. 北京: 清华大学出版社, 1997.

[11] 严蔚敏, 吴伟民. 数据结构[M]. 北京: 清华大学出版社, 1997.

[12] 王开义, 赵春江, 胥桂仙, 等. GIS 领域最短路径搜索问题的一种高效实现[J]. 中国图象图形学报, 2003, 8(5): 145-148.

KPCA和NS-LDA相结合的人脸识别研究

作者: [董吉文](#), [赵磊](#), [李秀丽](#)
作者单位: [济南大学 信息科学与工程学院, 山东 济南 250022](#)
刊名: [计算机技术与发展](#)
英文刊名: [Computer Technology and Development](#)
年, 卷(期): 2013 (5)

本文链接: http://d.g.wanfangdata.com.cn/Periodical_wjfz201305028.aspx