

基于优化的 LMNLDA 的人脸识别研究*

苗春玉, 闫德勤

(辽宁师范大学 数学学院, 辽宁 大连 116029)

摘要: 提出了一种优化的 LMNLDA 的人脸识别方法。为了减弱边缘类对投影方向的主导作用, 重新定义类间散度矩阵, 克服了边缘类对选择最佳投影方向的影响, 从而达到最优化。同时, 在计算特征值时通过因数分解的方法避免了对矩阵求逆, 解决了小样本问题。在人脸数据库 YALE、ORL 和 PIE 上进行试验, 证明实验结果的有效性。

关键词: 线性判别分析; 散度矩阵; 最大边际近邻元分析; 边缘类; 人脸识别

中图分类号: TP18

文献标识码: A

文章编号: 1674-7720(2011)12-0068-03

Study on face recognition based on optimized LMNLDA algorithm

Miao Chunyu, Yan Deqin

(Department of Mathematics, Liaoning Normal University, Dalian 116029, China)

Abstract: Advanced an optimized LMNLDA algorithm for face recognition, redefined the term of scatter matrix and overcame the effects of edge-class, when choosing the optimal projection direction. At the same time, it avoids computing the inverse of matrix by means of factorization, and solves the Small Sample problem (SSS). In order to prove the effectiveness of the experimental results, we could conduct a test in face database including YALE, ORL and PIE.

Key words: linear discriminant analysis; scatter matrix; largest margin neighbor discriminant analysis; edge-class; face recognition

人脸识别特指利用分析比较人脸视觉特征星系进行身份鉴别的计算机技术, 是一项热门的计算机技术研究, 它属于生物特征识别技术, 是人工智能与模式识别领域以及计算机视觉领域最富挑战性的研究课题之一。特征提取是人脸识别中极其关键的一步。线性判别分析 (LDA) 也叫做 Fisher 线性判别 (FLD), 是模式识别的经典算法, 其基本思想是将高维的样本投影到低维最佳鉴别矢量空间, 投影后保证样本在该空间中有最佳的可分离性。但 LDA 算法过度强调了边缘类与其他类的类间距离大小, 导致在投影空间中近邻类样本的重叠。LDA 算法在人脸识别应用中常遇到两个问题: (1) SSS 小样本问题 (Small Sample Size)^[1]; (2) 边缘类的存在造成投影空间中近邻样本重叠的问题。而一种改进的 LDA 算法——最大边际近邻元判别分析方法 (LMNLDA) 可以有效地克服样本类间数据重叠, 增加了样本间的相似度来描述数据之间关系, 于是重新定义散度矩阵, 从而得到

该判别准则。

如图 1 所示, 考虑一个 M 维的样本模型投影到一维空间, 假定有一个边缘类 4 与类 1、类 2、类 3 相隔较远, 则根据传统 LDA 算法得到的最佳投影方向 A 夸大了与其他 3 个类的类间距离较大的、可分性很好的类 4, 但却造成了类间距离本来就小的类 1、类 2、类 3 的彼此重叠。因此, 就分类性而言, 基于 Fisher 准则得到的鉴别方向并不是最优的, 最大边际近邻元判别分析方法同样没

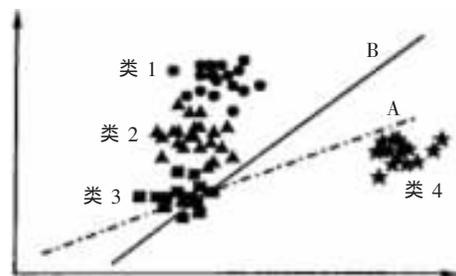


图 1 不同定义的 S_b 导出不同的投影方向

* 基金项目: 中国科学院自动化研究所复杂系统与智能科学重点实验室开放课题基金 (20070101);

辽宁省教育厅高等学校科学研究基金 (2008344)

技术与方法

Technique and Method

有对这类问题进行解决。

1 传统的 LDA 方法及 LMNLDA 方法

1.1 传统的 LDA 方法

假设训练数据集 $X = \{x_1, x_2, \dots, x_c\}$, 其中 $x_k, k=1, 2, \dots, c$ 是第 k 类数据集。LDA 的目的是从高维特征空间里找出最有分类信息的低维特征, 即寻找一个变换矩阵 G , 使得类内尽可能紧凑, 类间尽可能分离。通常用离散度来刻画样本的分布, 于是得到 Fisher 准则:

$$J(G_{opt}) = \arg \max_G \frac{|G^T S_b G|}{G^T S_w G} \quad (1)$$

其中, $S_b = \sum_{i=1}^c p_i (\mu_i - \mu) (\mu_i - \mu)^T$, $S_w = \frac{1}{N} \sum_{i=1}^c \sum_{x \in c_i} (x - \mu_i) (x - \mu_i)^T$,

$p_i = \frac{N_i}{N}$ 是每个类的先验概率, N_i 是 $c_i (i=1, 2, \dots, c)$ 类的训练样本的总个数, $\mu_i = \frac{1}{N} \sum_{x \in c_i} x$ 为 c_i 样本的均值, $\mu = \frac{1}{N} \sum_x x$

为所有样本的均值。由(1)式, 利用特征分解的方法求解 G , 如式(2):

$$S_b G = S_w G \Lambda \quad (2)$$

此时, $S_i = S_b + S_w$ 。式(1)为矩阵 S_b 相对于矩阵 S_w 的广义 Rayleigh 熵^[2]。

1.2 LMNLDA 方法

最大边际近邻元判别分析方法 (LMNLDA) 是一种改进的 LDA 算法。假设 $\{(x_i, y_i)\}_{i=1}^n$ 表示一个样本输入集, 其中 $x_i \in R^D, y_i$ 表示每一类的类别。用二进制矩阵 $y_{ij} \in \{0, 1\}$ 来表示类别 y_i 和 y_j 是否匹配, 并且矩阵 y_{ij} 是固定的, 用变换 L 来决定样本之间的度量^[3]。首先对于每一个输入样本 $x_i \in R^D$, 根据 k 近邻原则, 采用欧式距离来进行距离度量, 定义如下的惩罚函数:

$$\varepsilon(L) = \varepsilon_{pull}(L) + \varepsilon_{push}(L) \quad (3)$$

此函数包括两部分, 即在新的线性空间内, “引力”部分迫使拉近目标近邻点的距离使之尽量紧凑在一起, “斥力”部分迫使不同于输入样本类别的其他点尽量离得远一些。两部分相互对立、相互制约。最后, 利用交替投影算法对式(3)进行优化取得最小值, 进而求得最优变换矩阵 L 。

于是, 在新的变换空间中, 获得的新的类内、类间和总体散布矩阵为:

$$S_b^{new} = L S_b + \sum_{i=1}^c \sum_{j=1}^c (\mu_i - \mu_j) (\mu_i - \mu_j)^T + \exp(-||L^T \mu_i - L^T \mu_0||)$$

$$S_w^{new} = L S_w + \sum_{i=1}^c \sum_{j=1}^{N_i} (x_i - x_j) (x_i - x_j)^T + \exp(-||L^T x_j - L^T x_i||^2)$$

因此, 得到新的判别准则为: $G_{opt}^{new} = \arg \max_G \frac{|G^T S_b^{new} G|}{G^T S_w^{new} G}$ 。

该方法能够克服样本类间数据重叠并且增加了一种描述数据之间关系的样本间相似度, 但并未解决边缘类对选择投影方向的影响及矩阵 S_w^{new} 的奇异问题。

2 优化的 LMNLDA (OLMNLDA) 方法

在计算等式 $S_b G = S_w G \Lambda$ 时的一个普遍问题是求 S_w 的逆, 例如利用零空间方法, 也就是忽略了零空间之后的列空间。但是 Chen 等^[4] 曾经验证了 S_w 包含了重要的判别信息, 如果去掉零空间, 则会丢失掉一部分有价值的信息, 因此这里通过因数分解保持了信息的完整性, 将等式(2)转化为:

$$\left[\sum_{j=1}^q \hat{b}_j \hat{b}_j^T \right] G = G \Lambda$$

其中, $\hat{b}_j = \sum_{i=1}^p \frac{\lambda_{b_j}}{\lambda_{\mu_i}} \mu_i^T b_j \mu_i$ (4)

\hat{b}_j 是向量 b_j 的重构, $\lambda_{b_j}, \lambda_{\mu_i}$ 分别是 S_b, S_w 的特征值 ($j=1, \dots, q (q=c-1), i=1, \dots, p (p=N-c)$), q 和 p 分别为 S_b 与 S_w 的秩。显然, 式(4)避免了对 S_w 求逆, 解决了 S_w 的奇异问题^[5]。

可以看出式(4)中 $\frac{\lambda_{b_j}}{\lambda_{\mu_i}} \langle \mu_i^T, b_j \rangle$ 为一变化数值, b_j 的重构好坏取决于 λ_{μ_i} 和 μ_i 的取值。因而可对 \hat{b}_j 重新定义为

$\hat{b}_j = \sum_{i=1}^e \frac{\lambda_{b_j}}{\lambda_{\mu_i}} \mu_i^T b_j \mu_i$, 其中 $e (e \leq p)$ 的取值直接影响向量 b_j

的重构效果, 依据经验选取适当的 e 值可以得到更佳的人脸识别效果。因此为了减弱边缘类对投影方向的主导作用, \tilde{S}_b^{new} 重新定义为:

$$\tilde{S}_b^{new} = L S_b + \sum_{i=1}^c \sum_{j=1}^c (\mu_i - \mu_j) (\mu_i - \mu_j)^T + \exp(-||L^T \mu_i - L^T \mu_0||)$$

其中 $\tilde{S}_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c p_i p_j w(d_{ij}) (\mu_i - \mu_j) (\mu_i - \mu_j)^T$, p_i, p_j 是类 i, j 的先验概率, d_{ij} 为 c_i 类和 c_j 类均值向量间的欧氏距离, $d_{ij} = \sqrt{(\mu_i - \mu_j)^T (\mu_i - \mu_j)}$, 而 $w(d_{ij}) = (d_{ij})^{-2p}$, $p=1, 2, 3, \dots$, 这里 $p =$

\tilde{S}_b^{new} 的定义中考虑了类间距离的方向, 这样不但克服了样本间数据重叠, 又有效解决了边缘类对选取投影方向影响的问题, 则如下:

$$\tilde{S}_b^{new} = L S_b + \sum_{i=1}^c \sum_{j=1}^c (\mu_i - \mu_j) (\mu_i - \mu_j)^T + \exp(-||L^T \mu_i - L^T \mu_0||)$$

$$\tilde{S}_i^{new} = \tilde{S}_b^{new} + S_w^{new}$$

因此, 得到新的判别准则为:

$$\tilde{G}_{opt}^{new} = \arg \max_G \frac{|G^T \tilde{S}_b^{new} G|}{G^T S_w^{new} G}$$

根据新得到的判别准则进而得到广义判别准则如下:

技术与方法

Technique and Method

$$\hat{G}_{opt}^{new} = \arg \max \frac{\left| \tilde{G}^T \tilde{S}_b^{new} G \right|}{\left| \tilde{G}^T \tilde{S}_w^{new} G \right| + \left| \tilde{G}^T \tilde{S}_b^{new} G \right|}$$

$$= \arg \max \frac{\left| \tilde{G}^T \tilde{S}_b^{new} G \right|}{\left| \tilde{G}^T \tilde{S}_t^{new} G \right|}$$

参考文献[6]已经证明广义判别准则和一般判别准则是

等价的,即: $\hat{G}_{opt}^{new} = \tilde{G}_{opt}^{new}$ 。

3 实验结果

为了测试优化的 LMNLDA 算法的识别性能,本文采用 Yale 人脸数据库、ORL 人脸数据库和 PIE 人脸数据库进行了识别对比实验。

3.1 采用 Yale 人脸数据库的实验

采用国际通用的 Yale 人脸数据库,该数据库由 15 人,每人 11 幅,共 165 幅人脸正面 256 级灰度图像组成,每幅图像大小为 243 mm×320 mm。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,人脸姿态也有相当程度的变化。图 2 所示为预处理后的同一个人的人脸图像,共选择 105 个图像为训练集,其余的 60 个图像为测试集。



图 2 Yale 人脸数据库中某一个人的 10 幅图像

3.2 采用 ORL 人脸数据库上的实验

ORL 人脸数据库由剑桥大学实验室 1992 年 4 月到

1994 年 4 月拍摄的一系列人脸图像组成,具体为 40 个人,每个人由不同表情或不同视点的 10 幅图像构成,倾斜角度不超过 20°。人脸库中某一个人的 10 幅图像如图 3 所示,一共选择了 280 个图像为训练集,其余的 120 个图像为测试集。



图 3 ORL 人脸数据库中某一个人的 10 幅图像

3.3 采用 PIE 人脸数据库的实验

PIE 人脸数据库拥有 68 人,有不同的姿势,不同的灯光条件,以及不同的明暗表情等差别,其中包括了每个人的 13 种姿态条件,43 种光照条件和 4 种表情下的照片。如图 4 所示的一部分图像,一共选择 340 个图像为训练集,其余的 11 214 个图像为测试集。



图 4 PIE 人脸数据库中某一个人的 10 幅图像

3.4 实验结果分析

如表 1、表 2、表 3 表示 5 种方法在取相同特征维数的情况下的识别率比较,通过对 3 种人脸数据库的实验结果对比可以看出,本文所提出的优化的 LMNLDA 算法的识别率比其余 4 种方法的识别率都要高,5 种算法呈现一个大体的趋势,就是在一个确定的维数即本征维数上识别率最高,维数越大,识别率越趋于平衡。从以上的实验结果可以看出,在相同特征维数的情况下 OLMNLDA 优于其余 4 种算法,克服了边缘类对选择最佳投影

表 1 在 Yale 人脸库的识别结果比较

D	10	15	20	25	30	35	40	45	50	55	60
YPCA	45	48.33	51.67	55	56.67	58.33	58.33	60	60	60	60
YPCA+LDA	76.67	81.67	78.33	75	80	76.67	78.33	78.33	71.67	78.33	80
YMMC	68.33	75	75	70	70	68.33	68.33	65	65	73.33	71.67
YPCA+LMNLDA	77.12	84.72	79.33	76	79	77	80.55	80.17	80	80	80.17
YPCA+OLMNLDA	78.36	86.43	80.15	78	80	82.48	83.17	85	85	86	87

表 2 在 ORL 人脸库的识别结果比较

D	10	15	20	25	30	35	40	45	50	55	60
OPCA	64.17	75.83	76.67	75.83	78.33	79.17	79.17	79.17	79.17	79.17	79.17
OPCA+LDA	91.67	94.17	93.33	94.17	95	95	95	95	95	95	95
OMMC	80	85	87.5	87.5	88.33	90	90	90	90	90	90
OPCA+LMNLDA	90	97.67	94.17	94.17	96.13	96.14	96.40	96.57	96.60	96.61	96.63
OPCA+OLMNLDA	92.36	98.15	96	96	98.37	97.23	98.35	97.23	97.36	97.34	98

表 3 在 PIE 人脸库的识别结果比较

d	10	15	20	25	30	35	40	45	50	55	60
PPCA	50.13	52.33	57.33	60	60.47	61.52	60.56	60.48	60.43	60.57	60.77
PPCA+LDA	50.23	56.82	59.33	60.83	61.72	62.08	62.52	63.08	63	63.17	63.47
PMMC	41.10	45.63	47.95	49.65	50.95	52.15	52.98	53.71	53.91	54.06	54.24
PPCA+LMNLDA	60.33	65.44	65.13	64.48	63.48	65	64.88	64.98	64.89	64.99	64.78
PPCA+OLMNLDA	65.34	67.50	67.25	66.13	65.34	67	65.45	67.45	67.67	68.34	68.78

技术与方法 Technique and Method

方向的影响,进而能得到较为满意的效果。实验结果充分证明了本文算法的有效性。

参考文献

- [1] BELHUMEUR P N, HESPANHA J P, KRIEGMAN D J, et al. Fisherfaces: Recognition using class specific linear projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [2] 张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2004.
- [3] KILIAN Q, WEINBERGER L K, SAUL. Distance metric distance metric learning for large margin nearest neighbor classifiers[J]. Journal of Machine Learning Research, 2009 (10): 207-244.
- [4] CHEN L, LIAO H, KO M, 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.

- [5] MARTINEZ A M, ZHU M. Where are linear feature extraction methods applicable[J]. IEEE Trans. On Pattern Analysis and Machine Intelligence, 2005, 27(1): 1934-1944.
- [6] LIU K, CHENG Y Q, YANG J Y, et al. An efficient algorithm for Foley-Sammon optimal set of discriminant vectors by algebraic method[J]. Int. J. Pattern Recog. Artif. Intell., 1992, 6(5): 817-829.

(收稿日期: 2010-12-24)

作者简介:

苗春玉, 女, 1984年生, 硕士, 主要研究方向: 数据降维、模式识别、图像检索等。

闫德勤, 男, 1962年生, 教授, 博士, 主要研究方向: 模式识别、数字水印和数据挖掘等。

