

一种新的用于人脸识别的特征提取方法

冯海亮 王丽 李见为

(重庆大学光电技术及系统教育部重点实验室 重庆 400030)

摘要 由于特征提取在模式识别中占据非常重要的位置,提出了一种非线性的特征提取方法。该方法通过结合 LTSA 和 LDA 算法来构造目标函数,通过优化该目标函数,可以提取非线性特征。该方法的主要优点是可以充分地利用训练样本的非线性结构和类别信息。在 ORL 和 PIE 数据库上的试验证明了算法的有效性。

关键词 人脸识别,非线性特征,特征提取,SLTSA 算法

中图分类号 TP391.41 **文献标识码** A

New Feature Extraction Method of Face Recognition

FENG Hai-liang WANG-li LI Jian-wei

(Key Lab. on Opto-Electronic Technique of State Education Ministry of China, Chongqing University, Chongqing 400030, China)

Abstract Feature extraction is a crucial step for pattern recognition. A nonlinear extraction method was proposed. The objective function of the proposed method was formed by combining the ideas of locally tangent space alignment (LTSA) and linear discriminant analysis (LDA). Optimizing the objective function in a kernel feature space, nonlinear features can be extracted. A major advantage of the proposed method is that it makes full use of both the nonlinear structure and class-specific information of the training data. Experimental results on the ORL and PIE face database demonstrate the effectiveness of the proposed method.

Keywords Face recognition, Nonlinear feature, Feature extraction, SLTSA algorithm

1 引言

特征提取是模式识别特别是人脸识别中的关键步骤,特征脸和 Fisher 脸是目前较为流行的人脸特征提取方法,它们的理论基础是主成分分析 (PCA)^[1,2] 和线性判别分析 (LDA)^[3],主成分分析是为了寻找一个子空间,该子空间中的数据可以很好地描绘原始数据集。因此,通过主成分分析所提取的特征是最具表现力的特征^[5]。然而,主成分分析不能发现数据的局部结构。由于导致人脸表现不同的因素有很多,比如表情、光照和姿态等,所以人脸空间的流形是非常复杂的,虽然该流形的结构可以通过局部切空间排列算法 LTSA^[6-9] 获取,但是 LTSA 又不能直接映射新的测试样本。

另外,LTSA 和 PCA 一样都是非监督学习方法,因此样本的类别信息丢失。LDA 是处理分类问题的非常有效的学习方法,它通过最小化类内散度矩阵和类间散度矩阵的比来提取一个线性变换矩阵。因此,通过 LDA 提取的特征被叫做最有判别特征^[5]。相对于非监督算法 PCA 而言,当训练样本集为稀疏情况时^[4](这种情况在人脸识别中经常发生),LDA 倾向于过拟合。

为了结合 LTSA 和 LDA 的优点,同时抑制它们的缺点,我们制定一个目标函数,该目标函数在最小化 LTSA 目标函数的同时也能最小化 LDA 的目标函数。因此,我们可以得到

线性特征的规则。然后,我们通过核矩阵将输入空间映射到高能特征空间,将以上求得的线性特征转化为非线性特征。最后子空间的维数约减问题就转变为特征值求解问题。为简便起见,记该算法为 SLTSA。

2 SLTSA 算法简介

假设 $X=[x_1, x_2, \dots, x_N]$ 是 D 维空间中的数据集, N_c 代表属于第 c 类的样本个数。特征提取就是将输入空间中的点投影到 d 维空间中,其中 $d \ll D$ 。假设输入空间通过非线性函数 $\phi: X \rightarrow F$ 映射到 Hilbert 空间 F 。在进行详细推导之前,将 SLTSA 的步骤介绍如下:

Step 1 通过 K 近邻方法为数据集 $\{\phi(x_i)\}_{i=1}^{N_c}$ 中的每一个数据点分配近邻,得到矩阵 X_i 并将其中中心化得到 \bar{X}_i 。其中的距离是通过核矩阵 $K_{N \times N}$ 计算,其中 $K_{ij} = (\phi(x_i))^T \phi(x_j) = \phi(x_i) \cdot \phi(x_j)$;

Step 2 计算矩阵 \bar{X}_i 的最大 d 个奇异值对应的右奇异向量,组成矩阵 V_i ;

Step 3 构造矩阵 Φ, G, L, H 和 $Q, \Phi = \sum_{i=1}^{N_c} S_i W_i W_i^T S_i^T$, 其中 S_i 满足 $K S_i = K_i, W_i = I - [1_k / \sqrt{k}, V_i][1_k / \sqrt{k}, V]^T, G = I - (1/N)ee^T, L = I - E, H = G - L$, 其中 I 代表单位矩阵, $e = (1, \dots, 1)^T$, 如果 x_i, x_j 属于同一类则 $E_{ij} = 1/N_c$, 否则 $E_{ij} = 0, \theta$ 是一个权重参数。

到稿日期:2009-01-20 返修日期:2009-04-09 本文受重庆市自然科学基金项目(ID:CSTC2006BB2152,CTSC2008B2160)资助。

冯海亮(1962-),男,博士,副教授,主要研究方向为流形学习、模式识别, E-mail: fhliang@cqu.edu.cn; 王丽(1983-),硕士生,主要研究方向为流形学习、模式识别; 李见为(1947-),教授,博士生导师,主要研究方向为流形学习、模式识别、生物特征识别。

Step 4 计算广义特征方程: $KQK\beta = \lambda KHK\beta$ 的解矩阵 $B = [\beta_1, \dots, \beta_d]$, 相应地 $\lambda_1 < \dots < \lambda_d$;

Step 5 非线性特征可以表示为: $y_i^T = \sum_{j=1}^N \beta_j^T K_{ij}$, $n=1, \dots, d$.

3 算法分析

3.1 线性形式

LTSA 的基本思想是利用样本点邻域的切空间来表示局部的几何性质, 然后将这些局部切空间排列起来构造流形的全局坐标. 嵌入坐标 y_i 可以通过最小化重构误差

$$J = \min_Y \sum_i \|Y_i(I - 1_k 1_k^T)(I - \Theta_i, \Theta_i)\|^2 = \text{tr}\{Y\Phi Y^T\} \quad (1)$$

其中 $\Theta_i, i=1, \dots, N$ 是各样本点的局部坐标系. 由 LTSA 算法的原理可以看出, 该算法不能直接计算训练样本以外的数据点集. 为了解决这一问题, 我们假设在输入空间和嵌入空间存在线性映射关系 $y_i = A^T x_i$, 将 $y_i = A^T x_i$ 加入式(1), 我们可以得到:

$$J(A) = \min_Y \sum_i \|Y_i(I - 1_k 1_k^T)(I - \Theta_i, \Theta_i)\|^2 = \text{tr}\{A^T X \Phi X^T A\} = \text{tr}\{A^T (X \Phi X^T) A\} \quad (2)$$

为了结合线性判别分析算法, 我们将 Fisher 准则添加到式(2)中, 根据 Fisher 准则, 我们应该最小化类内散度和类间散度矩阵的比. 因此, 可以建立一个新的目标函数: $J(A) = \theta \text{tr}\{A^T (X \Phi X^T) A\} + (1 - \theta) \text{tr}\{A^T S_w A\}$, 约束条件为 $A^T S_b A = I$, 其中 S_w, S_b 分别代表类内散度和类间散度矩阵, 参数 $0 \leq \theta \leq 1$ 是为了平衡内部几何结构和类别信息的权重, 带约束的最小化问题可以通过 Lagrange 函数: $L(a_i) = \theta a_i^T (X \Phi X^T) a_i + (1 - \theta) a_i^T S_w a_i + \lambda (1 - a_i^T S_b a_i)$ 来解决.

将上式对 a_i 求导并令其导数等于零, 可以得到

$$(\theta(X \Phi X^T) + (1 - \theta)S_w)a_i = \lambda_i S_b a_i, \lambda_1 < \dots < \lambda_d \quad (3)$$

3.2 非线性形式

在将线性形式向非线性推导之前, 将式(3)以紧凑的形式表达, 然后在 Hilbert 空间求解非线性特征. 由 LDA 算法可知, 类内散度矩阵和类间散度矩阵可表示为:

$$S_i = 1/N \sum_{i=1}^N (x_i - u)(x_i - u)^T = (1/N)X(I - (1/N)ee^T)X^T = XGX^T$$

$$S_w = \sum_{i=1}^c \sum_{x \in X_i} (x - u_i)(x - u_i)^T = X(I - E)X^T = XLX^T$$

$$S_b = S_i - S_w = X(G - I)X^T = XHX^T$$

其中 $G = I - (1/N)ee^T, L = I - E, H = G - L$. 那么式(3)就可以重写为 $[\theta(X \Phi X^T) + (1 - \theta)XLX^T]a = \lambda XHX^T a$, 令 $Q = \theta \Phi + (1 - \theta)L$, 可得

$$XQX^T a = \lambda XHX^T a \quad (4)$$

通过非线性映射 ϕ 将输入空间转化为 Hilbert 空间, 则式(4)转化为:

$$[\phi(x_1), \dots, \phi(x_N)]Q[\phi(x_1), \dots, \phi(x_N)]^T a = \lambda [\phi(x_1), \dots, \phi(x_N)]H[\phi(x_1), \dots, \phi(x_N)]^T a$$

由于特征向量是 F 空间中数据的线性组合, 因此必然存在系数 $\beta_i (i=1, \dots, N)$ 使 $a = \sum_{i=1}^N \beta_i \phi(x_i)$, 因此

$$[\phi(x_1), \dots, \phi(x_N)]Q[\phi(x_1), \dots, \phi(x_N)]^T \sum_{i=1}^N \beta_i \phi(x_i) =$$

$$\lambda [\phi(x_1), \dots, \phi(x_N)]H[\phi(x_1), \dots, \phi(x_N)]^T \sum_{i=1}^N \beta_i \phi(x_i)$$

在上式两边同乘以 $\phi(x_j)$, 可以得到

$$[\phi(x_j) \cdot \phi(x_1), \dots, \phi(x_j) \cdot \phi(x_N)]Q \sum_{i=1}^N \beta_i$$

$$\begin{bmatrix} \phi(x_1) \cdot \phi(x_i) \\ \vdots \\ \phi(x_N) \cdot \phi(x_i) \end{bmatrix} = \lambda [\phi(x_j) \cdot \phi(x_1), \dots, \phi(x_j) \cdot \phi(x_N)] H \sum_{i=1}^N \beta_i$$

$$\begin{bmatrix} \phi(x_1) \cdot \phi(x_i) \\ \vdots \\ \phi(x_N) \cdot \phi(x_i) \end{bmatrix}$$

由于矩阵 H, V 已知, 则求解上式的关键就在于特征空间 F 中两点之间的内积. 假设数据 $\{x_i\}_{i=1}^N \in R^D$ 已经给出, 核函数定义为 k :

$$R^D \times R^D \rightarrow R; (x_i, x_j) \mapsto k(x_i, x_j)$$

它满足 $k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$, 且多项式核和高斯核都满足这个条件. 在试验部分我们采用高斯核 $k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / \sigma^2) = \phi(x_i) \cdot \phi(x_j)$.

通过定义核矩阵 $K_{N \times N}$, 其中 $K_{ij} = k(x_i, x_j)$ 和向量 $\beta = [\beta_1, \dots, \beta_N]$, 方程式(4)可以转化为:

$$(KQK)\beta = \lambda (KHK)\beta \quad (5)$$

计算非线性特征问题归结为求解方程(5), 一旦求出方程(5)的解, 则非线性特征可以表示为: $y_i = a_n \cdot \phi(x_i) = \sum_{j=1}^N \beta_j^T K_{ij}$.

4 试验结果

为了验证 SLTSA 算法的有效性, 本文将 SLTSA 算法在常用的 ORL 人脸库和 CMU PIE 人脸库上进行了测试, 并将 SLTSA 算法与 LLE + LDA^[11], LLTSA^[10], Fisherface 以及 PCA 作了比较. 由局部切空间排列算法的性质可知, LTSA 低维空间的维数和近邻点数目的选择有关, 本文采用 LLTSA 中嵌入维数和近邻点的近似关系, 在确定最终降维维数的前提下, 得到在 ORL 和 CMU PIE 数据库中近邻点和识别率之间的关系曲线, 如图 1 和图 2 所示. 从 SLTSA 的算法中可以看出该算法的识别率还受参数 θ 的影响, 在固定最终维数的前提下, 可以得到在 ORL 和 PIE 上识别率和参数 θ 的关系曲线, 如图 3 和图 4 所示.




图 1 SLTSA 算法在 ORL 数据库中近邻点数目和识别率之间的关系曲线




图 2 SLTSA 算法在 PIE 数据库中近邻点数目和识别率之间的关系曲线




图 3 SLTSA 算法在 ORL 上参数 θ 和识别率之间的关系曲线




图 4 SLTSA 算法在 PIE 上参数 θ 和识别率之间的关系曲线

4.1 ORL 数据库

ORL 数据库包含了由 40 个人组成的 400 幅人脸图像, 每人包含 10 幅图像。图像的分辨率为 64×64 , 这些图像的变化主要在于面部轮廓及表情、人脸尺度、人脸位置、少许倾斜、少许遮掩和轻微的光照变化。实验中, 每个人前 5 幅图像作为训练样本, 后 5 幅图像作为测试样本。对于需要利用 PCA 方法预先进行维数约减的方法, 选择保留 95% 能量的主元数目, 各种算法在 ORL 数据库上识别率与鉴别维数之间的关系如图 5 所示。表 1 列出了实验中各种方法最高识别率及其对应的鉴别矢量数目以及消耗的时间。

4.2 CMU PIE 数据库

卡耐基-梅隆大学(CMU)的 PIE 数据库包含了 68 个人组成的 41368 张人脸图像。绝大多数人平均每人包含的图像数目为 170 张。这些图像充分反映了人脸的位置、光照和表情的变化。CMU PIE 是一个较大的人脸图像数据库, 本实验选用的图像为 5 个接近正面的人脸子集, 分别是 C05, C07, C09, C27 和 C29, 这些子集中的图像包含了充分的光照和表情变化。实验中, 选择每类的前 5 幅图像作为训练样本, 接着的 5 幅作为测试样本, 各算法在 PIE 数据库上识别率与鉴别维数之间的关系如图 6 所示。表 2 列出了实验中各种方法最高识别率及其对应的鉴别矢量数目以及消耗的时间。




图 5 不同方法在 ORL 数据库上识别率与鉴别维数之间的关系曲线




图 6 不同方法在 PIE 数据库上识别率与鉴别维数之间的关系曲线

表 1 图 5 中不同方法在 ORL 数据库上最高识别率及鉴别维数和消耗的时间之间的关系

Approach	Rate (%)	Max Dim (Reduced)	Consumed time (s)
Eigenfaces (PCA)	85.50	76 (70)	35.953
Fisherfaces (PCA+LDA)	94.00	39 (29)	35.016
LLE+LDA	87.00	39 (39)	27.672
SLTSA	94.50	39 (35)	41.094

结束语 从以上人脸识别的试验可以看出, 将局部切空间排列(LTSA)和线性判别分析(LDA)相结合的算法 SLTSA 能够取得较好的识别率, 这主要是因为将这两种方法相结合, 既可以利用 LTSA 学习出数据集的低维流形结构, 又可

以利用 LDA 将数据集投影到最佳特征空间中进行分类识别。从公开人脸数据库 ORL 和 PIE 的试验中可以看出, 新算法 SLTSA 在这两个数据库上的识别率都高于其它 3 种算法, 而且样本的复杂度越高, 这种优势会越明显, 如在 ORL 数据库中, 由于 ORL 数据库中的样本变化不剧烈, 因此 4 种算法都取得了较好的识别效果, SLTSA 也只会比 Fisher 算法的识别率高 0.5%, 但在复杂的 PIE 数据库上 SLTSA 的识别率比 Fisher 高 4.71%。但从消耗的时间看, SLTSA 算法的消耗时间比较多, 且随着样本复杂度的增加而成倍数增长, 这主要是因为 LTSA 算法中, 嵌入维数和近邻点数目有关, 为了得到合适的嵌入维数, 近邻点的数目会很大, 这就增加了计算的复杂度。

表 2 图 6 中不同方法在 PIE 数据库上最高识别率及鉴别维数和消耗的时间之间的关系

Approach	Rate (%)	Max Dim (Reduced)	Consumed time (s)
Eigenfaces (PCA)	25.59	100(96)	71.734
Fisherfaces (PCA+LDA)	59.41	42 (20)	47.484
LLE+LDA	52.35	68 (68)	161.422
SLTSA	64.12	68 (54)	121.531

参考文献

- [1] Jolliffe I T. Principal Component Analysis [M]. New York: Springer, 1986
- [2] 余晓梅, 徐丹. 基于外观的子空间人脸识别方法研究[J]. 计算机应用研究, 2007; 1001-3695
- [3] Belhumeur P N, Hespanha J P, Kriegman J. Eigenfaces vs fisherfaces recognition using class specific linear projections[J]. IEEE Trans. Pattern Anal Mach Intell, 1997, 19(7): 711-720
- [4] Martinez A M, Kak A C. PCA versus LDA[J]. IEEE Trans Pattern Analysis and Machine Intelligence, 2001, 23(2): 228-233
- [5] Swets D, Weng J. Using discriminant eigenfeatures for image retrieval[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(8): 831-836
- [6] 黄启宏, 刘钊. 流形学习中非线性维数约简方法概述[J]. 计算机应用研究, 2007; 1001-1369
- [7] 罗四维, 赵连伟. 基于谱图理论的流形学习算法[J]. 计算机研究与发展, 2006; 1173-1179
- [8] Zhang Zhenyue, Zha Hongyuan. Linear low-rank approximations and non-linear dimensionality reduction [J]. Science in China Series A-Mathematics, 2005, 35(3): 273-285
- [9] Zhang Zhenyue, Zha Hongyuan. Principal manifolds and non-linear dimensionality reduction via tangent space alignment [J]. SIAM Journal of Scientific Computing, 2004, 26(1): 313-338
- [10] Zhang Tianhao, Yang Jie, Zhao Deli, et al. Linear local tangent space alignment and application to face recognition [J]. Neurocomputing, 2007, 70: 1547-1553
- [11] Pang Yanwei, Liu Zhengkai, Yu Nenghai. A new nonlinear feature extraction method for face recognition [J]. Neurocomputing, 2006, 69: 949-953

(上接第 267 页)

所用的密写方法, 而只需通过固定的方法提取秘密信息, 很大程度上减少了传递过程中的共享信息, 提高了密写的安全性。另外, 本算法还同时保持了小波域内密写算法鲁棒性好的特点, 从而在安全性和鲁棒性中达到了一个较为平衡的支点, 通过实验证明了本方法是一种非常实用的密写方法。

参考文献

- [1] Barni M, Bartolini F, Piva A. Improved Wavelet-based Watermarking Through Pixel-wise Masking[J]. IEEE Transactions on Image Processing, 2001, 10(5)

- [2] Xie Gui, Shen Hong. Toward Improved Wavelet-based Watermarking Using the Pixel-Wise Masking Model [C]//Image Processing 2005. ICIP 2005. IEEE International Conference. CA, USA, Sept. 2005, 1: 689-692
- [3] Fridrich J, Goljan M, Lisoněk P, et al. Writing on Wet Paper [J]. IEEE Transactions on Image Processing, 2005, 53(10)
- [4] Lewis A S, Knowles G. Image compression using the 2-D wavelet transform [J]. IEEE Trans. Image Processing, 1992, 1: 244-250
- [5] Brent R P, Gao S, Lauder A G B. Random Krylov spaces over finite fields [J]. Discrete Math., 2003, 16(2): 276-287
- [6] 许文丽, 苏万力, 等. 基于混沌置乱和混合变换域的扩频水印方案[J]. 计算机科学, 2007, 34(7): 248-251