

Journal of Image
and Graphics

中国图象图形学报



ISSN1006-8961
CN11-3758/TB

2013 2
Vol.18 No.

中国科学院遥感应用研究所
中国图象图形学学会主办
北京应用物理与计算数学研究所

中国图象图形学报

Zhongguo Tuxiang Tuxing Xuebao

2013 年 2 月 第 18 卷 第 2 期(总第 202 期)

目次

计算机视觉前沿论坛

- 计算机视觉——探索行为理解,认知内心世界 徐光祐,刘允才,章毓晋(131)
- 跨学科前沿与应用的交汇点:日常活动理解 徐光祐,陶霖密,邸慧军(132)
- 时空行为理解 章毓晋(141)
- 视觉机制研究对机器视觉的启发示例 李雄,刘允才(152)
- 视点无关的行为识别综述 冯家更,肖俊(157)

图像处理和编码

- 基于演化算法的卷曲 DCT 图像压缩 李康顺,韦蕴珊,张文生(169)
- 基于欧氏距离图的图像边缘检测 张闯,王婷婷,孙冬娇,葛益娴,常建华(176)
- 基于暗原色先验模型的快速去雾算法 张冰冰,戴声奎,孙万源(184)

图像分析和识别

- Gabor 特征集结合判别式字典学习的稀疏表示图像识别 胡正平,徐波,白洋(189)
- 半监督 k 近邻分类方法 陈日新,朱明早(195)
- 最小距离鉴别投影及其在人脸识别中的应用 黄璞,唐振民(201)
- 图像 LSB 匹配隐藏的预分类检测模型 曹卫权,韩杰思,王宏霞(207)
- 具有旋转鲁棒性的纹理谱描述子 陈刚,陈晓云(214)

计算机图形学

- 利用形体特征的铅笔素描画生成 莫晓斐,丁友东(219)

医学图像处理

- 统计相似度特征的医学图像分割 郭艳蓉,蒋建国,郝世杰,詹曙,李鸿(225)

遥感图像处理

- 结合遗传算法和蚁群算法的高光谱图像波段选择 王立国,魏芳洁(235)
- 相似度自适应样本块的高分辨 SAR 图像阴影修复 赵昊,张弓(243)

- 第八届国际数字地球会议征稿通知 封 3

Journal of Image and Graphics

(Monthly, Started in 1996)

Vol. 18 No. 2 February 2013

Contents

Forum: Forefront of Computer Vision

Confluence of interdisciplinary frontiers and real-world application: understanding activities of daily living

..... Xu Guangyou, Tao Linmi, Di Huijun (132)

Understanding spatial-temporal behaviors Zhang Yujin (141)

The motivation of visual mechanisms to machine vision: examples Li Xiong, Liu Yuncai (152)

View-invariant action recognition: a survey Feng Jiageng, Xiao jun (157)

Image Processing and Coding

Warped DCT image compression based on an evolutionary algorithm Li Kangshun, Wei Yunshan, Zhang Wensheng (169)

Image edge detection based on the Euclidean distance graph

..... Zhang Chuang, Wang Tingting, Sun Dongjiao, Ge Yixian, Chang Jianhua (176)

Fast image haze-removal algorithm based on the prior dark-channel

..... Zhang Bingbing, Dai Shengkui, Sun Wanyuan (184)

Image Analysis and Recognition

Sparse representation for image recognition based on Gabor feature set and discriminative dictionary learning

..... Hu Zhengping, Xu Bo, Bai Yang (189)

Semi-supervised k -nearest neighbor classification method Chen Rixing, Zhu Minghan (195)

Minimum-distance discriminant projection and its application to face recognition Huang Pu, Tang Zhenmin (201)

Using pre-classification to attack LSB matching Cao Wei-quan, Han Jiesi, Wang Hongxia (207)

Robust rotation-invariant texture spectrum descriptor Chen Gang, Chen Xiaoyun (214)

Computer Graphics

Pencil sketch generation with shape features Mo Xiaofei, Ding Youdong (219)

Medical Image Processing

Medical image segmentation based on statistical similarity feature

..... Guo Yanrong, Jiang Jianguo, Hao Shijie, Zhan Shu, Li Hong (225)

Remote Sensing Image Processing

Band selection for hyperspectral imagery based on combination of genetic algorithm and ant colony algorithm

..... Wang Liguang, Wei Fangjie (235)

Adaptive shadow inpainting from high-resolution SAR image based on exemplar's similarity Zhao Hao, Zhang Gong (243)

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2013)02-201-06

论文引用格式: 黄璞, 唐振民. 最小距离鉴别投影及其在人脸识别中的应用[J]. 中国图象图形学报, 2013, 18(2): 201-206.

最小距离鉴别投影及其在人脸识别中的应用

黄璞, 唐振民

南京理工大学计算机科学与技术学院, 南京 210094

摘要: 针对人脸识别问题, 提出了最小距离鉴别投影算法, 其与经典的线性鉴别分析不同, 它是一种流形学习降维算法。该算法首先定义样本的类内相似度与类间相似度: 前者能够度量样本与类内中心的距离关系, 后者不仅能够反映样本与类间中心的距离关系而且能够反映样本类间距与类内距的大小关系; 然后将高维数据映射到低维特征空间, 使得样本到类内中心距离最小同时到类间中心距离最大。最后, 在 ORL、FERET 及 AR 人脸库上的实验结果表明所提算法识别性能要优于其他算法。

关键词: 人脸识别; 降维; 线性鉴别分析; 局部保持投影; 最小距离

Minimum-distance discriminant projection and its application to face recognition

Huang Pu, Tang Zhenmin

School of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing 210094, China

Abstract: A minimum-distance discriminant projection (MDP) algorithm is proposed to address face recognition problem. Different from the classical linear discriminant analysis (LDA), the MDP is a manifold learning based dimensionality reduction algorithm. MDP first defines the intra-class similarity, weight, and the inter-class weight of each sample. The former one can measure the distance between each data point and the intra-class center, while the latter one does not only characterize the distance between the data point and the inter-class center but also can reflect the relation between the between-class distance and the within-class distance. Then, the high-dimensional data is mapped into a low-dimension space such that the points to within-class center distances are minimized while the points to between-class center distances are maximized simultaneously. At last, experiments on the ORL, FERET, and AR face databases show that the proposed algorithm can outperform other algorithms.

Key words: face recognition; dimensionality reduction; linear discriminant analysis; locality preserving projections; minimum distance

0 引言

人脸识别是模式识别领域一个研究热点, 其在身份认证、信用卡验证、档案管理及人机交互等方面有着广泛的应用前景。人脸识别技术一个关键难点

在于如何对高维人脸图像数据进行降维, 从而提高识别效率。

主分量分析 (PCA)^[1] 与线性鉴别分析 (LDA)^[2] 是最经典的两种降维算法。然而, PCA 与 LDA 均是基于样本整体结构的算法, 并不能刻画样本的流形结构。近年来的研究表明, 高维人脸图

收稿日期: 2012-07-03; 修回日期: 2012-08-16

基金项目: 国家自然科学基金项目 (90820306); 江苏省普通高校研究生科研创新计划项目 (CXZZ12_0204)

第一作者简介: 黄璞 (1985—), 男, 现为南京理工大学模式识别与智能系统专业博士研究生, 主要研究方向为模式识别、图像处理。

E-mail: huangpu3355@163.com

像数据极可能存在于一个非线性流形上。为刻画样本的流形结构,研究者们提出了一些流形学习算法,如局部线性嵌入 (LLE)^[3]、拉普拉斯特征映射 (laplacian eigenmap)^[4]、等距映射 (Isomap)^[5] 等。然而,这些算法均为非线性的,且仅能够处理已知样本,对于未知样本并不能产生有效映射,因此泛化能力较低。He 等人提出了一种线性流形学习算法局部保持投影 (LPP)^[6],其基本思想是在低维空间中保持样本之间的近邻关系。LPP 能够产生 1 组对已知及未知样本均有效的投影向量,因此泛化能力较强。然而,LPP 属于无监督算法,并没有利用样本类别信息,因此 LPP 并不适用于分类工作。针对此问题,一些研究者在 LPP 基础上通过加入类别信息提出了一些改进算法,如鉴别局部保持投影 (DLPP)^[7]、边界费舍尔分析 (MFA)^[8] 及中心近邻嵌入^[9]等。另一方面,LPP 仅考虑样本的局部结构,这对分类并无直接联系,Yang 等人在考虑局部结构的同时考虑非局部结构提出了无监督鉴别投影 (UDP)^[10],此外还有一些 UDP 的改进算法^[11-13]。

在 LPP 及其改进算法中,样本的相似性度量对于刻画样本间近邻关系起着至关重要的作用。然而,LPP 所采用的核权重仅能够反映样本间的距离关系。针对此点,在 LDA 的基础上,提出了最小距离鉴别投影 (MDP)。MDP 引入了类内相似度与类间相似度,不仅能够反映样本与类中心的距离关系,同时能够反映样本类间距与类内距的大小关系。经过投影后,样本类内距离减小,同时类间距离扩大。在 ORL、FERET 及 AR 人脸库上的实验结果验证了 MDP 的有效性。

1 LDA

设有 n 个训练样本 $X = [\mathbf{x}_1, \dots, \mathbf{x}_n] \in \mathbf{R}^{N \times n}$,且这 n 个训练样本可被分为 C 类 $X_1, \dots, X_C$ 。线性降维算法是利用 1 组投影向量 $\mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_d] \in \mathbf{R}^{N \times d} (d < N)$ 将样本 $\mathbf{x}_i$ 映射到 d 维特征空间,从而得到样本在低维空间的表示: $y_i = \mathbf{A}^T \mathbf{x}_i$ 。在本文中,为方便讨论,先考虑 1 维投影向量 $\mathbf{a}$ 的情况。

LDA 的基本思想是找到一条投影方向,使得样本投影后,类内散度最小同时类间散度最大。样本的类内散度与类间散度分别计算为

$$\tilde{S}_w = \sum_{c=1}^C \sum_{i=1}^{n_c} (y_i^c - \tilde{m}_c)^2 \quad (1)$$

$$\tilde{S}_b = \sum_{c=1}^C n_c (\tilde{m}_c - \tilde{m}_0)^2 \quad (2)$$

式中, n_c 为第 c 类样本数, $y_i^c = \mathbf{a}^T \mathbf{x}_i^c$, $\tilde{m}_c = \mathbf{a}^T \mathbf{m}_c$ 与 $\tilde{m}_0 = \mathbf{a}^T \mathbf{m}_0$ 为投影后的数据, $\mathbf{x}_i^c$ 表示第 c 类第 i 个样本, $\mathbf{m}_c$ 为第 c 类样本均值, $\mathbf{m}_0$ 为总体样本均值。

LDA 的目标函数为

$$J_{\text{LDA}} = \arg \max_a \frac{\tilde{S}_b}{\tilde{S}_w} \quad (3)$$

2 MDP

2.1 基本思想

根据文献[14],当每类样本数相同时,LDA 准则函数中样本的类间散度可等价地表示为

$$\tilde{S}_b = \sum_{c=1}^C \sum_{i=1}^{n_c} \sum_{k=1, k \neq c}^C (y_i^c - \tilde{m}_k)^2 \quad (4)$$

结合式(1)(4)可知,当每类样本数相同时,LDA 准则函数的实质是通过最小化样本与类内中心点的距离同时最大化样本与类间中心点的距离,来达到同类样本相互靠近且不同类样本相互分离的目的。

LDA 是一种基于样本整体结构的算法,并不能刻画样本之间的近邻关系,针对此问题,MDP 通过引入样本与类中心点的相似度权重来刻画样本与类中心点的近邻关系。

2.2 目标函数

在 MDP 中,定义样本的类内散度与类间散度分别为

$$\begin{aligned} \tilde{S}'_w &= \sum_{c=1}^C \sum_{i=1}^{n_c} w_{ic} (y_i^c - \tilde{m}_c)^2 = \\ &= \sum_{c=1}^C \sum_{i=1}^{n_c} w_{ic} (\mathbf{a}^T \mathbf{x}_i^c - \mathbf{a}^T \mathbf{m}_c)^2 = \\ &= \mathbf{a}^T \left[\sum_{c=1}^C \sum_{i=1}^{n_c} w_{ic} (\mathbf{x}_i^c - \mathbf{m}_c) (\mathbf{x}_i^c - \mathbf{m}_c)^T \right] \mathbf{a} = \\ &= \mathbf{a}^T \mathbf{S}'_w \mathbf{a} \end{aligned} \quad (5)$$

$$\begin{aligned} \tilde{S}'_b &= \sum_{c=1}^C \sum_{i=1}^{n_c} \sum_{k=1, k \neq c}^C b_{ik} (y_i^c - \tilde{m}_k)^2 = \\ &= \sum_{c=1}^C \sum_{i=1}^{n_c} \sum_{k=1, k \neq c}^C b_{ik} (\mathbf{a}^T \mathbf{x}_i^c - \mathbf{a}^T \mathbf{m}_k)^2 = \\ &= \mathbf{a}^T \left[\sum_{c=1}^C \sum_{i=1}^{n_c} \sum_{k=1, k \neq c}^C b_{ik} (\mathbf{x}_i^c - \mathbf{m}_k) (\mathbf{x}_i^c - \mathbf{m}_k)^T \right] \mathbf{a} = \\ &= \mathbf{a}^T \mathbf{S}'_b \mathbf{a} \end{aligned} \quad (6)$$

式中

$$S'_w = \sum_{c=1}^C \sum_{i=1}^{n_c} w_{ic} (\mathbf{x}_i^c - \mathbf{m}_c) (\mathbf{x}_i^c - \mathbf{m}_c)^T \quad (7)$$

$$S'_b = \sum_{c=1}^C \sum_{i=1}^{n_c} \sum_{k=1, k \neq c}^C b_{ik} (\mathbf{x}_i^c - \mathbf{m}_k) (\mathbf{x}_i^c - \mathbf{m}_k)^T \quad (8)$$

分别为样本的类内散布矩阵与类间散布矩阵。

类似于 LDA, 定义 MDP 准则函数为

$$J_{\text{MDP}} = \arg \max_a \frac{\tilde{S}'_b}{\tilde{S}'_w} = \arg \max_a \frac{\mathbf{a}^T S'_b \mathbf{a}}{\mathbf{a}^T S'_w \mathbf{a}} \quad (9)$$

类似于文献[2]中 LDA 的求解方法, 要求满足 MDP 准则函数的投影向量, 只需求解 \$(S'_w)^{-1} S'_b d\$ 个最大特征值对应的 \$d\$ 个特征向量 \$\mathbf{a}_1, \dots, \mathbf{a}_d\$。

2.3 权重定义

\$w_{ic}\$、\$b_{ik}\$ 分别表示 \$\mathbf{x}_i^c\$ 与类内中心点、第 \$k\$ (\$k \neq c\$)

类中心点的相似度权重, 其权值分别定义为

$$w_{ic} = \exp(-\|\mathbf{x}_i^c - \mathbf{m}_c\|^2/t) \quad (10)$$

$$b_{ik} = \begin{cases} \frac{\exp(-\|\mathbf{x}_i^c - \mathbf{m}_k\|^2/t)}{\exp(-\|\mathbf{x}_i^c - \mathbf{m}_c\|^2/t)} > \sigma \\ 0 & \text{其他} \end{cases} \quad (11)$$

式中, \$\|\mathbf{x}_i^c - \mathbf{m}_c\|\$ 表示 \$\mathbf{x}_i^c\$ 与 \$\mathbf{m}_c\$ 之间的欧氏距离, \$t > 0, 0 \leq \sigma < 1\$ 为可调节参数。

所定义相似度权重具有如下特性:

1) \$0 < w_{ic} \leq 1\$, 对于类内相似度来说, \$\mathbf{x}_i^c\$ 与类内中心点 \$\mathbf{m}_c\$ 距离越近, 权重 \$w_{ic}\$ 越大, 反之越小。经过投影后, 权重越大的样本离类内中心点更近。

2) 对于类间相似度来说, 所定义权重同样能够反映 \$\mathbf{x}_i^c\$ 与类间中心点 \$\mathbf{m}_k\$ 之间的距离关系: 对于 \$\mathbf{x}_i^c\$ 来说, 其与类内中心点距离 \$\|\mathbf{x}_i^c - \mathbf{m}_c\|\$ 是固定的, 因此 \$\mathbf{x}_i^c\$ 与类间中心点 \$\mathbf{m}_k\$ 距离越近, 相似度权重 \$b_{ik}\$ 越大, 样本投影后与第 \$k\$ 类样本越易分离。另外, \$b_{ik}\$ 能够反映类间距 \$\|\mathbf{x}_i^c - \mathbf{m}_k\|\$ 与类内距 \$\|\mathbf{x}_i^c - \mathbf{m}_c\|\$ 的关系: 若 \$\|\mathbf{x}_i^c - \mathbf{m}_k\| > \|\mathbf{x}_i^c - \mathbf{m}_c\|\$, 则权重 \$0 < b_{ik} < 1\$; 若 \$\|\mathbf{x}_i^c - \mathbf{m}_k\| \leq \|\mathbf{x}_i^c - \mathbf{m}_c\|\$, 则 \$b_{ik} \geq 1\$。由于样本的类中心代表了该类信息, 若存在 \$\|\mathbf{x}_i^c - \mathbf{m}_k\| \leq \|\mathbf{x}_i^c - \mathbf{m}_c\|\$, 则说明 \$\mathbf{x}_i^c\$ 与第 \$k\$ 类相似性反而可能大于自身所属类 \$c\$, 因此通过赋予 \$b_{ik}\$ 一个较大的权重, 使得 \$\mathbf{x}_i^c\$ 投影后与第 \$k\$ 类样本距离更大, 而若采用 LPP 中的核权重在这种情形下是不具有此点特性的。

2.4 MDP 算法

根据前文所述, 可以得到 MDP 算法如下:

1) 根据式 (10) 计算样本 \$\mathbf{x}_i^c\$ 与类内中心点 \$\mathbf{m}_c\$ 之间的相似度, 根据式 (11) 计算 \$\mathbf{x}_i^c\$ 与类间中心点 \$\mathbf{m}_k\$ (\$k \neq c\$) 之间的相似度。

2) 分别根据式 (7) (8) 计算类内散布矩阵 \$S'_w\$ 与类间散布矩阵 \$S'_b\$。

3) 求解 \$(S'_w)^{-1} S'_b d\$ 个最大特征值对应的 \$d\$ 个特征向量 \$\mathbf{a}_1, \dots, \mathbf{a}_d\$。令 \$\mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_d]\$, 则某一样本 \$\mathbf{x}\$ 在 \$d\$ 维特征空间中的表示为 \$\mathbf{y} = \mathbf{A}^T \mathbf{x}\$。

4) 根据样本 \$\mathbf{x}\$ 在 \$d\$ 维特征空间中的表示, 可采用某一分类器对 \$\mathbf{x}\$ 进行分类, 在本文中选择最近邻分类器进行分类。

3 MDP 与 LDA、LPP 的比较

与 LDA 相比, MDP 属于流形学习算法, 能够刻画样本与类中心点之间的近邻关系, 而 LDA 是一种基本样本整体结构的降维算法。另外, 当 \$t\$ 趋于正无穷大、\$\sigma = 0\$ 时, 可以验证, MDP 等价于每类样本数相等时的 LDA。

与 LPP 相比, MDP 主要有以下优势: LPP 属于无监督算法, 而 MDP 属于监督的算法; LPP 中所定义的相似度权重仅能够反映样本之间的距离关系, MDP 则能够包含更多的样本与类中心之间的距离关系; LPP 仅考虑样本的局部保持特性, 而 MDP 同时考虑了样本的内聚性与分离性。

4 实验

为验证所提算法的有效性, 将 MDP 与其他一些算法 (如 LDA、LPP、DLPP 与 MFA) 在 ORL、FERET 及 AR 人脸库上进行实验, 并将实验结果进行了比较。

4.1 ORL 人脸库

ORL 人脸库中包括 40 人, 每人 10 幅图像, 每幅图像分辨率为 \$112 \times 92\$。该库人脸图像在人脸表情、人脸的面部姿态方面均有不同程度的变化, 图 1 为 ORL 人脸库中某人的 10 幅图像。

4.1.1 人脸识别

本实验采用每人前 4 幅图像作为训练样本, 后 6 幅图像作为测试样本。由于人脸样本维数较高 (常常高达上万维), 因此在实际运行算法时首先采用 PCA 对初始图像作降维, 投影轴数取为 40。表 1



图 1 ORL 库中某人 10 幅图像
Fig. 1 Ten images of one person in the ORL database

为 MDP 在 t 与 σ 取不同值时的识别率。
由表 1 可知,参数 t 与 σ 的选择均会对识别率产

生不同程度的影响,当 t 取值为 10^7 , σ 取值分别为 0.3 与 0.5 时,MDP 取得了较高的两个识别率 93.33% 与 93.75%。

4.1.2 高维数据低维可视化

人脸图像维数通常较高,而人的视觉感觉最多只有 3 维,因此高维数据在空间中是不可视的,也就无法看出这些数据之间的内在联系且无法直观地看出各种人脸识别算法的差异性。为此在 ORL 库上进行了可视化实验。实验时,选择库中前 5 个人,每人 10 幅图像,共 50 幅图像,分别采用 LDA、LPP 与 MDP 进行训练学习,将初始的 10 304 维图像数据映射到 2 维空间,映射结果如图 2 所示。

表 1 ORL 库中 MDP 在 t 与 σ 取不同值时的识别率及相应投影维数
Table 1 Recognition rates and corresponding dimensions of MDP with different t and σ on the ORL database

	$\sigma=0.1$	$\sigma=0.3$	$\sigma=0.5$	$\sigma=0.7$	$\sigma=0.9$
$t=10^6$	92.50(18)	87.08(10)	87.08(10)	85.00(15)	85.00(15)
$t=10^7$	91.25(19)	93.33(19)	93.75(18)	92.92(37)	87.50(13)
$t=10^8$	90.42(19)	90.42(19)	90.42(19)	90.83(21)	92.08(18)

注:括号内为投影维数。




图 2 LPP、LDA 与 MDP 的 2 维投影结果
Fig. 2 Two-dimensional projection results of LPP, LDA and MDP

由于 LPP 属于无监督降维算法,并且其权重仅能反映两样本之间的距离关系,因此 LPP 映射后数据的类属关系非常模糊。相较于 LPP,由于 LDA 利用了样本的类别信息,且同时考虑了样本的内聚性与分离性,因此分类效果较好,然而 LDA 仅能清晰地分离出 3 类样本,其中两类样本类属关系仍不明确。图 2(c)(d)分别为 MDP 在 σ 取 0.3、0.5 时的

映射结果,相较于 LPP 与 LDA,MDP 能够更好地分离出 5 类样本。

4.2 FERET 人脸库

FERET 人脸库中包含 200 人,每人 7 幅图像,每幅图像分辨率大小为 80×80 。该人脸库图像在人脸表情、姿态光照等方面均有变化,图 3 为 FERET 人脸库中某人的 7 幅图像。



图3 FERET 库中某人 7 幅图像

Fig. 3 Seven images of one person in the FERET database

在 FERET 库的实验分为两种情况进行:1)选择每人第 1、3、5 幅图像作为训练样本,剩余图像作为测试样本;2)选择每人前 3 幅图像作为训练样本,剩余图像作为测试样本。PCA 降维轴数取为 120,算法中参数选择如下:MDP 中, $t = 10^7$, $\sigma = 0.3$;LPP 中, $t = 10^7$, $k = 2$;DLPP 中, $t = 10^7$;MFA 中, $k_1 = 2$, $k_2 = 100$ 。表 2 为 MDP 与其他算法在两种情况下的识别率比较结果。

由表 2 可知:1)样本的类别信息对于提高人脸识别率起着至关重要的作用,监督的算法 LDA、DLPP、MFA、MDP 识别率均高于无监督算法 LPP;2)在情况 1 中,MFA 取得了较 LDA、DLPP 更好的识别率,而在情况 2 中,MFA 识别率则低于 LDA 与 DLPP;3)DLPP 与 LDA 识别率相同;4)相较于其他算法,所提算法 MDP 在两种情况下均取得了最好的识别率。

4.3 AR 人脸库

AR 人脸库包括 120 人,每人有 26 幅图像,图像

分辨率为 50×40 。采用每人的 14 幅无遮挡图像作实验,图 4 为 AR 库中某人的 14 幅图像,在这 14 幅图像中,前 7 幅图像与后 7 幅图像拍摄于不同的时期,且每 7 幅图像中人脸姿态、表情、光照条件等均有变化。

表 2 FERET 库中 MDP 与其他算法识别率及相应投影维数
Table 2 Recognition rates and corresponding dimensions of MDP and other algorithms on the FERET database

		/%				
		LDA	LPP	DLPP	MFA	MDP
情况 1	识别率	72.88	50.88	72.88	74.38	75.25
	投影维数	40	120	40	40	40
情况 2	识别率	52.75	37.50	52.75	51.88	55.00
	投影维数	10	40	10	20	20



图4 AR 库中某人 14 幅图像

Fig. 4 Fourteen images of one person in the AR database

在 AR 库上,分别选择前 $l=3,4$ 幅图像作为训练样本,剩余图像作为测试样本。PCA 降维轴数取为 150,算法中参数选择如下:MDP 中, $t=10^7, \sigma=0.3$;LPP 中, $t=10^7, k=l-1$;DLPP 中, $t=10^7$;MFA 中, $k_1=l-1, k_2=100$ 。表 3 为 MDP 与其他算法的识别率比较结果。

由表 3 可知:1) 在选择不同训练样本数情况下,MDP 识别率仍然要高于其他算法;2) LPP 取得了最低识别率,这进一步验证了类别信息的重要性;3) MFA 同样属于一种监督流形学习算法,识别率仅次于 MDP。

表 3 AR 库中 MDP 与其他算法识别率及相应投影维数

Table 3 Recognition rates and corresponding dimensions of MDP and other algorithms on the AR database

训练样本数	LDA	LPP	DLPP	MFA	MDP	/%
3	71.59(110)	71.36(130)	71.59(110)	71.97(130)	72.05(140)	
4	67.41(110)	67.04(140)	67.41(110)	69.17(140)	69.50(140)	

注:括号内为投影维数。

5 结 论

提出一种监督流形学习算法最小距离鉴别投影。MDP 在 LDA 的基础上引入了两种相似性权重:类内权重与类间权重,分别用于表示样本与类内中心以及类间中心的近邻关系。相较于经典的流形学习算法 LPP,MDP 是一种监督算法,并且同时考虑了样本的内聚性及分离性,所定义的相似度量也能够包含更多的距离信息。在 ORL、FERET 及 AR 人脸库上的实验结果表明 MDP 相较于其他算法识别率更高、更有利于分类工作。

参考文献 (References)

- [1] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal Cognitive Neuroscience, 1991, 3(1): 71-86.
- [2] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces; recognition using specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [3] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326.
- [4] Belkin M, Niyogi P. Laplacian Eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396.
- [5] Tenenbaum J B, De S V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323.
- [6] He X F, Yan S C, Hu Y X, et al. Face recognition using laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.
- [7] Yu W W, Teng X L, Liu C Q. Face recognition using discriminant locality preserving projections [J]. Image and Vision Computing, 2006, 24(3): 239-248.
- [8] Yan S C, Xu D, Zhang B Y, et al. Graph embedding and extensions: a general framework for dimensionality reduction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.
- [9] Kong W Z, Zhu S A. Learning algorithm of center based neighborhood embedding for face recognition [J]. Journal of Image and Graphics, 2008, 13(4): 691-695. [孔万增,朱善安. 中心近邻嵌入学习算法的人脸识别研究[J]. 中国图象图形学报,2008,13(4): 691-695.]
- [10] Yang J, Zhang D, Yang J Y, et al. Globally maximizing, locally minimizing: unsupervised discriminant projection with applications to face and palm biometrics [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(4): 650-664.
- [11] Li B, Wang C, Huang D. Supervised feature extraction based on orthogonal discriminant projection [J]. Neurocomputing, 2009, 73: 191-196.
- [12] Yin J, Jin Z. Complete unsupervised discriminant projection and face image analysis [J]. Journal of Computer-Aided Design & Computer Graphics, 2010, 22(11): 1912-1917. [殷俊,金忠. 完备非监督鉴别投影与人脸图像分析 [J]. 计算机辅助设计与图形学学报,2010,22(11):1912-1917.]
- [13] Yan H, Yang J Y. Unsupervised difference discriminant feature extraction-with application to face recognition [J]. Journal of Computer-Aided Design & Computer Graphics, 2009, 21(11): 1632-1637. [严慧,杨靖宇. 无监督的差分鉴别特征提取以及在人脸识别上的应用 [J]. 计算机辅助设计与图形学学报, 2009, 21(11):1632-1637.]
- [14] Yang J, Zhang L, Zhang D. From classifier to discriminators: a nearest neighbor rule introduced discriminant analysis [J]. Pattern recognition, 2011, 44(7): 1387-1402.