

完备自适应近邻图嵌入的局部鉴别投影算法

王永茂 李 赓

(河南理工大学计算机科学与技术学院, 焦作, 454000)

摘要: 针对基于自适应近邻图嵌入的局部鉴别投影算法(Neighborhood graph embedding based local adaptive discriminant analysis, LADP)仅仅利用局部类内离差矩阵主元空间的鉴别信息而丢失了其零空间内大量鉴别信息的不足, 结合全空间的基本思想提出了完备的基于自适应近邻图嵌入的局部鉴别投影算法(Complete LADP, CLADP)。在局部类内离差矩阵的零空间内, 通过最大化局部类间离差矩阵提取不规则鉴别特征, 在局部类间离差矩阵的主元空间内, 通过最大化局部类间离差矩阵的同时最小化局部类内离差矩阵提取规则鉴别特征, 最后将不规则鉴别特征和规则鉴别特征串联形成 CLADP 特征。在 ORL, Yale 以及 PIE 人脸库上的人脸识别实验结果证明了 CLADP 的有效性。

关键词: 人脸识别; 自适应近邻图; 局部鉴别分析; 完备特征; 降维

中图分类号: TP391.4 **文献标志码:** A

Local Discriminant Projection Algorithm Based on Complete Adaptive Neighborhood Graph Embedding

Wang Yongmao, Li Geng

(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo, 454000, China)

Abstract: The existing adaptive neighborhood graph embedding method based on local discriminant projection(LADP) only uses discriminant information in the principle space of local within-class scatter matrix, which leads to the loss of discriminant information in the null space. To overcome the drawback of LADP, a complete LADP(CLADP) is proposed for face recognition. In the null space of local within-class scatter matrix, irregular discriminant features are extracted by maximizing the local between-class scatter matrix. In the principle space of local within-class scatter matrix, regular discriminant features are extracted by maximizing the local between-class scatter matrix and minimizing the local within-class scatter matrix. Finally, irregular discriminant features and regular discriminant features are combined as the features of CLADP for face recognition. The experimental results on ORL, Yale face database and PIE subset illustrate the effectiveness of the proposed CLADP.

Key words: face recognition; adaptive neighborhood graph; local discriminant analysis; complete feature; dimensionality reduction

引 言

在诸如人脸识别的应用领域中经常会遇到高维数据,降维是重要的预处理手段之一。降维的过程就是将高维数据投影到一个低维空间内,同时保持高维数据内在的本质特征。根据投影变换是否为线性变换,降维方法可以分为线性方法和非线性方法。主元成分分析(Principle component analysis, PCA)与线性鉴别分析(Linear discriminant analysis, LDA)^[1]是两种最为经典的线性降维方法。相比于线性降维方法,非线性降维方法可以很好地处理复杂的非线性分布的数据,非线性降维方法一般分为两大类:基于流形学习的降维方法^[2]和基于核空间的降维方法^[3]。经典的基于流形学习的降维方法包括:等距映射、局部线性嵌入(Locally linear embedding, LLE)以及拉普拉斯映射(Laplacian eigenmap, LE),但这些算法的最大缺陷就是不能映射新的测试样本,为此,局部 Fisher 鉴别分析(Local fisher discriminant analysis, LFDA)^[4]、局部保形投影(Locality preserving projection, LPP)^[5]以及近邻保持嵌入(Neighborhood preserving projection, 简称 NPE)^[6]等线性的基于流形学习的降维方法相继提出。另外基于核空间的降维方法也是近年来的一个重要研究方向,传统的线性降维方法可以利用核技巧得到其相应的非线性降维方法,如核主元成分分析(Kernel PCA, KPCA)和核线性鉴别分析(Kernel LDA, KDA)等。为了更好地揭示各种降维方法之间的共同特征, Yan 等提出了统一的图嵌入框架理论^[7],在降维的过程中,需要构造两类图,一个是固有图,用于描述在降维过程需要保持的几何特性;一个是惩罚图,用于描述在降维过程中需要避免的几何特性,现存的大部分降维方法都可以用图嵌入框架来描述,其差别仅仅表现在图构造的不同。

在降维的过程中,为了保持高维数据的流形结构,往往要根据数据的近邻点来构造固有图和惩罚图,然而近邻点个数的选择对于最优的投影变换影响较大。作者在文献[8]中根据样本的分布特性以及样本间的相似度自适应计算类内和类间的近邻点,提出了基于自适应近邻图嵌入的局部鉴别分析算法(Neighborhood graph embedding based local adaptive discriminant analysis, LADP)。然而,同其他降维方法一样, LADP 算法也是基于向量的降维方法,在进行降维前需要将数据转换为一维向量形式,这种转换大大增加了数据的维数,由于用于训练的数据个数有限,常常遭遇小样本问题^[9],这时局部类内离差矩阵通常为奇异矩阵。为解决这一问题,通常先利用 PCA 对样本进行降维,使得在 PCA 子空间内的局部类内离差矩阵为非奇异矩阵,这实际上仅仅利用了局部类内离差矩阵主元空间的鉴别信息而丢失了其零空间的大量鉴别信息。为了充分利用主元空间和零空间内的鉴别信息,基于全空间的特征提取算法^[10-12]得到了广泛的关注。本文将全空间的思想与 LADP 相结合,提出了完备的 LADP 算法(Complete LADP, CLADP),充分利用局部类内离差矩阵的零空间和主元空间内的鉴别信息。

1 基于自适应近邻图嵌入的局部鉴别分析算法

LADP 的基本思想为:根据数据分布自适应构造描述局部信息的类内与类间近邻图,避免了近邻点个数对于投影子空间的影响,在得到的低维子空间内,使得相同类别的近邻点尽量靠近,而不同类别的近邻点尽量分离。LADP 可以形式化描述如下:由 N 个样本组成的样本集记作 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, $\mathbf{x}_i \in \mathbf{R}^m$, \mathbf{x}_i 是一个 m 维向量; $l_i \in L = \{1, 2, \dots, M\}$ 为样本 \mathbf{x}_i 的类别标号; M 为类别总数。LADP 就是按照某种最优化标准得到一个 $m \times m'$ 变换矩阵 \mathbf{V} , 将样本集 \mathbf{X} 投影到低维空间得到 $\mathbf{Y} = \mathbf{V}^T \mathbf{X} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$, $\mathbf{y}_i \in \mathbf{R}^{m'}$, 其中, \mathbf{y}_i 是 \mathbf{x}_i 的低维投影,维数为 m' , 且 $m' < m$ 。在 Fisher 极大判别准则下,其目标式为

$$\max_{\mathbf{V} \in m \times m'} \frac{\mathbf{V}^T \mathbf{X} (\mathbf{D}^b - \mathbf{W}^b) \mathbf{X}^T \mathbf{V}}{\mathbf{V}^T \mathbf{X} (\mathbf{D} - \mathbf{W}) \mathbf{X}^T \mathbf{V}} \quad (1)$$

式中: \mathbf{W} 和 \mathbf{W}^b 分别为类内和类间近邻图的权值矩阵,其值反映了样本之间的近邻关系; \mathbf{D} 和 \mathbf{D}^b 为 $N \times$

N 的对角矩阵, 对角元素 $D_{ii} = \sum_{j=1}^N W_{ij}$, $D_{ii}^p = \sum_{j=1}^N W_{ij}^p$ 。 W 和 W^p 的取值为

$$\left. \begin{aligned}
 W_{ij} &= \begin{cases} \frac{1}{k_w(i)} & x_i \in N_w(x_j) \text{ 或者 } x_j \in N_w(x_i) \\ 0 & \text{其他} \end{cases} \\
 W_{ij}^p &= \begin{cases} \frac{1}{k_w(i) + k_b(i)} - \frac{1}{k_w(i)} & x_i \in N_w(x_j) \text{ 或者 } x_j \in N_w(x_i) \\ \frac{1}{k_w(i) + k_b(i)} & x_i \in N_b(x_j) \text{ 或者 } x_j \in N_b(x_i) \\ 0 & \text{其他} \end{cases}
 \end{aligned} \right\} \quad (2)$$

式中: $k_w(i)$ 为样本点 x_i 同类别的近邻点的个数, 其值为同类别的近邻点集合 $N_w(x_i)$ 中样本点的个数; $k_b(i)$ 为样本点 x_i 不同类别的近邻的个数, 其值为不同类别的近邻点集合 $N_b(x_i)$ 中样本点的个数。自适应计算同类别近邻点集合 $N_w(x_i)$ 与不同类别近邻点集合 $N_b(x_i)$ 分别为

$$N_w(x_i) = \left\{ x_j \mid l_j = l_i, \exp\left(-\frac{\|x_j - x_i\|^2}{\beta}\right) > AS(x_i) \right\} \quad (3)$$

$$N_b(x_i) = \left\{ x_j \mid l_j \neq l_i, \exp\left(-\frac{\|x_j - x_i\|^2}{\beta}\right) > AS(x_i) \right\} \quad (4)$$

式中: $AS(x_i)$ 为样本 x_i 与所有其他样本之间的平均相似度; β 为所有样本之间的欧式距离平均值, 其值为

$$AS(x_i) = \frac{1}{N} \sum_{j=1}^N \exp\left(-\frac{\|x_i - x_j\|^2}{\beta}\right) \quad (5)$$

$$\beta = \frac{1}{N^2} \sum_{i,j=1}^N \|x_i - x_j\|^2 \quad (6)$$

式(1)可以通过求解广义特征值问题得到

$$S_{\text{IB}} \mathbf{v} = \lambda S_{\text{IW}} \mathbf{v} \quad (7)$$

式中: $S_{\text{IW}} = \mathbf{X}(\mathbf{D} - \mathbf{W})\mathbf{X}^T$, $S_{\text{IB}} = \mathbf{X}(\mathbf{D}^p - \mathbf{W}^p)\mathbf{X}^T$ 称为局部类内和类间离差矩阵。如果 S_{IW} 为非奇异矩阵, 令 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{m'}$ 为式(7)最大的 m' 个最大特征值对应的特征向量, 则最优的变换矩阵为 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{m'}]_{m \times m'}$ 。

在 LADP 算法中, 为了使 S_{IW} 为非奇异矩阵, 首先利用 PCA 方法对样本数据进行降维, 使得 S_{IW} 在 PCA 子空间内满秩, 即所有的特征值均大于零, 因此 LADP 算法仅仅利用 S_{IW} 主元空间内的鉴别信息而丢失了 S_{IW} 零空间内大量的鉴别信息。本文提出了 CLADP 算法, 充分利用 S_{IW} 零空间和主元空间内的鉴别信息。

2 完善的 LADP 算法

2.1 去除鉴别无关信息

对于总体离差矩阵 $S_{\text{IT}} = S_{\text{IW}} + S_{\text{IB}}$, 其零空间由矩阵 S_{IB} 和 S_{IW} 的公共零空间组成, 在该空间内, 所有的样本均投影到同一点而无法区分, 所以 S_{IT} 的零空间内不含有任何鉴别信息, 所有的鉴别信息存在于 S_{IT} 的主元空间内。

首先利用 PCA 方法去除 S_{IT} 的零空间, 得到 S_{IT} 的主元空间, 即非零特征值对应的特征向量 $\mathbf{p}_i (i = 1, 2, \dots, r_i)$, $r_i = \text{rank}(S_{\text{IT}})$, 令 $\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_{r_i})$, 则 S_{IW} 和 S_{IB} 在 S_{IT} 的主元空间内的投影为

$$\tilde{S}_{\text{IW}} = \mathbf{P}^T S_{\text{IW}} \mathbf{P} \quad (8)$$

$$\tilde{S}_{\text{IB}} = \mathbf{P}^T S_{\text{IB}} \mathbf{P} \quad (9)$$

2.2 规则鉴别特征和不规则鉴别特征提取

$\bar{\mathbf{S}}_{\text{IW}}$ 的主元空间内的鉴别特征称为规则鉴别特征, $\bar{\mathbf{S}}_{\text{IW}}$ 的零空间内的鉴别特征称为不规则鉴别特征。设 $r_w = \text{rank}(\bar{\mathbf{S}}_{\text{IW}})$, 根据奇异值分解理论, $\bar{\mathbf{S}}_{\text{IW}}$ 可以分解为

$$\bar{\mathbf{S}}_{\text{IW}} = [\mathbf{Q}, \mathbf{Q}_\perp] \begin{bmatrix} \mathbf{D} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{Q} \\ \mathbf{Q}_\perp \end{bmatrix} \quad (10)$$

式中: \mathbf{Q} 为 $\bar{\mathbf{S}}_{\text{IW}}$ 的主元空间; \mathbf{Q}_\perp 为 $\bar{\mathbf{S}}_{\text{IW}}$ 的零空间; $\mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{r_w}, 0, \dots, 0)$ 。

(1) 规则鉴别特征提取

将 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$ 投影到 $\bar{\mathbf{S}}_{\text{IW}}$ 的主元空间, 得到

$$\bar{\mathbf{S}}_{\text{IW}} = \mathbf{Q}^T \bar{\mathbf{S}}_{\text{IW}} \mathbf{Q}, \bar{\mathbf{S}}_{\text{IB}} = \mathbf{Q}^T \bar{\mathbf{S}}_{\text{IB}} \mathbf{Q} \quad (11)$$

由于此时 $\bar{\mathbf{S}}_{\text{IW}}$ 为正定矩阵, 为非奇异矩阵, 最优的投影矩阵 \mathbf{V} 由 $(\bar{\mathbf{S}}_{\text{IW}}^{-1} \bar{\mathbf{S}}_{\text{IB}})$ 的前 l 个最大特征值对应的特征向量 $\mathbf{v}_i (i=1, 2, \dots, l)$ 组成, 即 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_l]$ 。

对于一个样本 \mathbf{x} , 其规则鉴别特征为

$$\mathbf{y}_r = \mathbf{A}_r^T \mathbf{x} \quad (12)$$

式中: $\mathbf{A}_r = \mathbf{PQV}$ 为规则鉴别特征的投影变换矩阵。

(2) 不规则鉴别特征提取

将 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$ 投影到 $\bar{\mathbf{S}}_{\text{IW}}$ 的零空间, 得到

$$\hat{\mathbf{S}}_{\text{IW}} = \mathbf{Q}_\perp^T \bar{\mathbf{S}}_{\text{IW}} \mathbf{Q}_\perp = \mathbf{0}, \hat{\mathbf{S}}_{\text{IB}} = \mathbf{Q}_\perp^T \bar{\mathbf{S}}_{\text{IB}} \mathbf{Q}_\perp \quad (13)$$

由于 $\hat{\mathbf{S}}_{\text{IW}} = \mathbf{0}$, 而 $\hat{\mathbf{S}}_{\text{IB}} = \hat{\mathbf{S}}_{\text{IW}} + \hat{\mathbf{S}}_{\text{IB}} > \mathbf{0}$, 因此可知 $\hat{\mathbf{S}}_{\text{IB}} > \mathbf{0}$, 所以 $\hat{\mathbf{S}}_{\text{IB}}$ 为正定矩阵, 则 $\text{rank}(\hat{\mathbf{S}}_{\text{IB}}) = r_t - r_w$, 这时需要最大化 $\hat{\mathbf{S}}_{\text{IB}}$, 最优投影矩阵 \mathbf{R} 由 $\hat{\mathbf{S}}_{\text{IB}}$ 的 $r_t - r_w$ 个最大特征值对应的特征向量 $\mathbf{r}_i (i=1, 2, \dots, r_t - r_w)$ 组成, 即 $\mathbf{R} = [\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_{r_t - r_w}]$ 。对于一个样本 \mathbf{x} , 其不规则鉴别特征为

$$\mathbf{y}_{\text{ir}} = \mathbf{A}_{\text{ir}}^T \mathbf{x} \quad (14)$$

式中: $\mathbf{A}_{\text{ir}} = \mathbf{PQ}_\perp \mathbf{R}$ 为不规则特征的变换矩阵。

2.3 两种鉴别特征融合

对于给定的一个样本 \mathbf{x} , CLADP 算法可以得到 l 个规则鉴别特征以及 $r_t - r_w$ 个不规则鉴别特征, 将两类特征串联起来得到维度为 $r_t - r_w + l$ 的鉴别特征, 则最终的 CLADP 特征为 $\mathbf{y} = (\mathbf{y}_{\text{ir}}, \mathbf{y}_r)$ 。根据以上分析, CLADP 算法的算法描述如下。

(1) 自适应计算 \mathbf{x}_i 的类内和类间近邻点集合, 根据类内类间近邻点个数构建类内类间近邻图的权值矩阵 \mathbf{W} 和 \mathbf{W}^p , 进而得到 \mathbf{S}_{IW} , \mathbf{S}_{IB} 与 \mathbf{S}_{IT} 。

(2) 利用 PCA 方法, 去除 \mathbf{S}_{IT} 的零空间, 仅保留 \mathbf{S}_{IT} 的主元空间 \mathbf{P} , 计算 \mathbf{S}_{IW} 与 \mathbf{S}_{IB} 在 \mathbf{S}_{IT} 的主元空间 \mathbf{P} 上的投影 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$ 。

(3) 对 $\bar{\mathbf{S}}_{\text{IW}}$ 进行奇异值分解, 得到 $\bar{\mathbf{S}}_{\text{IW}}$ 的主元空间 \mathbf{Q} 和零空间 \mathbf{Q}_\perp 。

(4) 计算 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$ 在 $\bar{\mathbf{S}}_{\text{IW}}$ 主元空间 \mathbf{Q} 上的投影 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$, 得到 $(\bar{\mathbf{S}}_{\text{IW}}^{-1} \bar{\mathbf{S}}_{\text{IB}})$ 的前 l 个最大特征值对应的特征向量 \mathbf{v}_i 组成的投影矩阵 \mathbf{V} , 得到规则特征的投影变换矩阵 $\mathbf{A}_r = \mathbf{PQV}$ 。

(5) 计算 $\bar{\mathbf{S}}_{\text{IW}}$ 和 $\bar{\mathbf{S}}_{\text{IB}}$ 在 $\bar{\mathbf{S}}_{\text{IW}}$ 零空间 \mathbf{Q}_\perp 上的投影 $\hat{\mathbf{S}}_{\text{IW}}$ 和 $\hat{\mathbf{S}}_{\text{IB}}$, 得到由 $\hat{\mathbf{S}}_{\text{IB}}$ 的 $r_t - r_w$ 个最大特征值对应的特征向量 \mathbf{r}_i 组成的投影矩阵 \mathbf{R} , 得到不规则特征的投影变换矩阵 $\mathbf{A}_{\text{ir}} = \mathbf{PQ}_\perp \mathbf{R}$ 。

3 实验结果与分析

为了评估本文提出的 CLADP 算法的性能, 设计两类实验, 实验 1 在 ORL 人脸库上, 通过低维空间的可视化比较 CLADP 与 LFDA, LADP 的鉴别能力, 对于 CLADP 算法, 比较分别采用规则鉴别特征, 不规则鉴别特征以及融合两种特征的识别性能; 实验 2 在 Yale 和 PIE 人脸库上比较 CLADP 与 PCA,

LDA,LFDA 与 LADP 等算法的分类性能。

3.1 ORL 人脸库上的实验

ORL 人脸库是由英国剑桥大学建立,共有 40 个人,每人 10 张图像,共有 400 张人脸图像,图像的面部表情和面部细节有着不同程度的变化,人脸姿势也有相当程度的变化,比较充分地反映了同一人不同人脸图像的变化和差异,ORL 人脸库图像经剪切后大小均为 32 像素×32 像素,用一个 1 024 维的向量表示。图 1 是 ORL 人脸库的部分样本。



图 1 ORL 人脸数据库
Fig.1 ORL face database

3.1.1 实验 1

通过对低维空间的可视化来比较 CLADP 与 LDA,LFDA,LADP 的鉴别能力。在实验中,随机从 ORL 人脸库中选取 6 个人的人脸图像,分别用符号“*”,“□”,“○”,“+”,“△”和“☆”表示,任意选择每个人的 5 幅图像作为训练图像,剩余的图像作为测试图像,分别采用 LDA,LFDA,CLADP 和 LADP 等算法将其投影到二维子空间内,LFDA 算法中近邻点的个数 $k=4$,LDA,LFDA 与 LADP 算法中 PCA 步骤,保持 99% 的主元能量,图 2 为 ORL 人脸库上 6 人脸的二维子空间可视化结果。

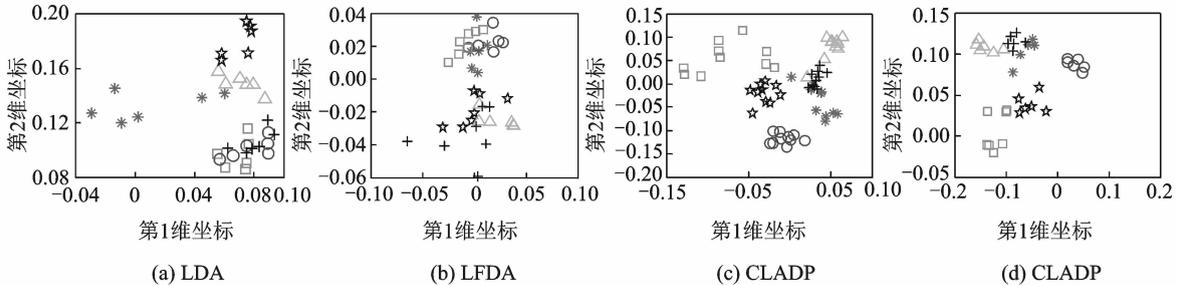


图 2 ORL 图像库上 6 人脸的二维子空间

Fig.2 Two dimension subspace of six persons in ORL face database

为了更加有效清晰比较各种算法的鉴别能力,采用 Fisher 标准值(Fisher criterion,FC)来评价在二维子空间内样本之间的区分程度^[13],FC 定义如下

$$FC = \text{trace}(\mathbf{S}_w^{-1}\mathbf{S}_b) \tag{15}$$

式中: \mathbf{S}_w 和 \mathbf{S}_b 分别为二维子空间内样本类内和类间离散矩阵。FC 值越大,说明在相应的子空间内的不同类别的样本的区分度越大,即鉴别能力越强。表 1 为在 ORL 人脸库的二维子空间内,各种算法的 FC 值。

表 1 二维子空间内人脸 Fisher 标准值

Table 1 Face fisher criterion in two dimension subspace

算法	LDA	LFDA	LADP	CLADP
FC	3.91	2.47	6.66	17.52

从图 2 可以看出,对于 ORL 人脸库,在 CLADP 算法得到二维子空间内 6 个人的人脸图像具有较大的区分程度,LDA,LFDA 与 LADP 算法得到的子空间内不同类别的人脸具有不同程度的交叠,反映在 FC 值上,CLADP 为 17.52,LADP,LFDA 与 LDA 分别为 6.66,2.47 与 3.91,说明在二维子空间内,CLADP 的鉴别能力最强,LADP 与 LDA 次之,LFDA 最弱。

3.1.2 实验 2

对于 CLADP,比较分别采用规则鉴别特征,不规则鉴别特征以及融合两种特征的识别性能。实验中,随机选取每一个人的 3 幅图像组成训练样本集,剩余的图像组成测试样本集,重复进行 10 次,共得到 10 组不同的训练样本集和测试样本集。表 2 所示为分别采用规则特征,不规则特征以及融合两种特征的平均最高识别率以及对应的维数。从表 2 可以看出,单独采用规则鉴别特征其平均最高识别率为 85.36%,单独采用不规则鉴别特征其平均最高识别率为 87.69%,而融合了规则和不规则鉴别特征的 CLADP 算法的平均识别率进一步提高至 88.19%。

表 2 不同特征下 LADP 算法的识别率

Table 2 Recognition rate of LADP based on different features

特征	规则特征	不规则特征	融合两种特征
最高识别率/%	85.36	87.69	88.19
维数	36	39	43

3.2 Yale 以及 PIE 人脸库上的实验

通过在 Yale 以及 PIE 人脸库上的实验,比较本文提出的 CLADP 与 PCA,LDA,LFDA 和 LADP 等算法的识别性能。Yale 人脸库由美国耶鲁大学建立,包含 15 个人,每人 11 张图像,共有 165 张人脸图像,主要包括光照条件的变化(左侧光照、右侧光照、中央光照),表情的变化(正常、高兴、悲伤、睡眠、惊讶、眨眼)及有无眼睛修饰等。PIE 人脸图像库由 68 人的 41 368 幅不同姿态、不同光照、不同表情的图像组成。在本文中,选择了仅包括光照变化的 20 人的正面人脸的 400 张人脸图像组成的 PIE 子库(每人 20 张图像)作为实验图像。在实验中,所有图像均根据眼睛坐标进行旋转、剪切、缩放到大小为 32 像素×32 像素的图像,未作任何其他处理。图 3 显示了预处理后各人脸图像库的图像示例。

在每个库上进行实验,从每一个类别中选取 m 个样本组成训练样本集,记作 G_m ,其余的 n 个样本组成测试样本集,记作 P_n ,然后利用各种特征提取方法提取特征,最后利用欧式距离作为相似度度量的最近邻分类器完成分类任务,每组实验均重复 10 次。对于 PCA 以及 LDA,LFDA,LADP 中 PCA 步骤,实验中保持 99% 的能量,另外,LFDA 中的近邻点个数 k 设置为 $n-1$, n 为训练样本集中每一个类别的个数。表 3 和表 4 分别给出了各种特征提取方法在 Yale 以及 PIE 上的平均最高识别率(括号中的数值为对应的维数)。

表 3 Yale 图像库上的平均最高识别率

Table 3 Maximal average recognition rate on Yale face database %

算法	G_3/P_8	G_4/P_7	G_5/P_6
PCA	48.71(44)	54.62(59)	55.00(74)
LDA	62.33(13)	69.62(14)	73.56(14)
LFDA	66.00(15)	72.48(17)	75.56(18)
LADP	67.25(24)	73.24(19)	79.44(15)
CLADP	71.67(16)	76.20(17)	80.56(16)



(a) Yale人脸库

(a) Yale face database



(b) PIE人脸子库

(b) PIE face sub database

图3 预处理后的图像

Fig. 3 Preprocessed face images

表4 PIE图像库上的平均最高识别率

算法	G_4/P_{16}	G_5/P_{15}	G_6/P_{14}
PCA	34.84(78)	39.10(99)	44.71(119)
LDA	74.09(19)	79.30(19)	82.54(19)
LFDA	73.22(20)	77.83(42)	81.18(40)
LADP	74.13(31)	81.13(33)	84.93(41)
CLADP	79.31(23)	84.17(24)	88.54(24)

从表3和表4可以看出,本文提出的CLADP算法在Yale和PIE人脸库上均取得了较好的识别效果。在Yale人脸库上,CLADP算法的识别率平均比PCA算法高23.37%,比LDA算法高7.64%,比LFDA算法高4.8%,比LADP算法高2.83%;在PIE人脸子库上,CLADP算法的识别率平均比PCA算法高44.46%,比LDA算法高5.36%,比LFDA算法高6.6%,比LADP算法高3.94%。随着训练样本的增加,CLADP与PCA,LDA,LFDA,LADP等算法的识别率都相应地提高。

4 结束语

本文在分析LADP算法仅仅利用局部类内离差矩阵主元空间内鉴别信息的不足之处的基础上,提出了同时利用主元空间和零空间内鉴别信息的CLADP算法,由于零空间的鉴别信息对于识别任务具有更加重要的作用,因此相较于LADP算法,CLADP算法具有更强的识别性能。通过人脸识别实验,本文将CLADP算法与PCA,LDA,LFDA,LADP等4种流行的降维算法进行比较,实验结果表明CLADP算法具有最好的识别率。

参考文献:

- [1] Martinez A M, Kak A C. PCA versus LDA[J]. IEEE Trans Pattern Analysis and Machine Intelligence, 2001, 23(2):228-

233.

- [2] 陈国明. 数据降维中若干问题的研究及应用[D]. 广州: 中山大学, 2009.
Chen Guoming. Research and application of several problems in data dimensionality reduction[D]. Guangzhou: Sun Yat-Sen University, 2009.
- [3] 林月娥. 特征提取方法研究及其在人脸识别中的应用[D]. 哈尔滨: 哈尔滨工程大学, 2009.
Lin Yue'e. Research and application of feature extraction for face recognition[D]. Harbin: Harbin Engineering University, 2009.
- [4] Sugiyama M. Dimensionality reduction of multimodal labeled data by local Fisher discriminant analysis[J]. *Journal of Machine Learning Research*, 2007, 8(5): 1027-1067.
- [5] He X F, Niyogi P. Locality preserving projection[C]//Proceedings of the 16th Advances in Neural Information Processing Systems. Vancouver, Canada; Neural Information Processing Systems Foundation, 2003: 153-160.
- [6] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding [C]// Proceedings of 10th IEEE International Conference on Computer Vision. Beijing, China: IEEE, 2005: 1208-1213.
- [7] Yan S C, Xu D, Zhang B Y, et al. Graph embedding and extension: A general framework for dimensionality reduction[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2007, 29(1): 40-51.
- [8] 王永茂, 徐正光, 赵珊. 基于自适应近邻图嵌入的局部鉴别投影算法[J]. *电子与信息学报*, 2013, 35(3): 633-638.
Wang Yongmao, Xu Zhengguang, Zhao Shan. Neighborhood graph embedding based local adaptive discriminant projection [J]. *Journal of Electronics and Information Technology*, 2013, 35(3): 633-638.
- [9] 江艳霞, 任波. 基于加权邻域极大边界准则的人脸识别[J]. *数据采集与处理*, 2011, 26(5): 515-520.
Jiang Yanxia, Ren Bo. Face recognition based on weighted neighborhood maximum margin criterion[J]. *Journal of Data Acquisition and Processing*, 2011, 26(5): 515-520.
- [10] 杨利平, 龚卫国, 辜小花, 等. 完备鉴别保局投影人脸识别算法[J]. *软件学报*, 2010, 21(6): 1277-1286.
Yang Liping, Gong Weiguang, Gu Xiaohua, et al. Complete discriminant locality preserving projections for face recognition[J]. *Journal of Software*, 2010, 21(6): 1277-1286.
- [11] 殷俊, 金忠. 完备非监督鉴别投影于人脸图像分析[J]. *计算机辅助设计与图像学学报*, 2010, 22(11): 1913-1918.
Yin Jun, Jin Zhong. Complete unsupervised discriminant projection and face image analysis[J]. *Journal of Computer Aided Design and Computer Graphics*, 2010, 22(11): 1913-1918.
- [12] Wang Y, Wu Y. Complete neighborhood preserving embedding for face recognition[J]. *Pattern Recognition*, 2010, 43(3): 1008-1015.
- [13] Raducanu B, Dornaika F. A supervised non-linear dimensionality reduction approach for manifold learning[J]. *Pattern Recognition*, 2012, 45(6): 2432-2444.

作者简介:



王永茂 (1976-), 男, 博士, 副教授, 研究方向: 图像处理与模式识别, E-mail: wy-myjs2000@hpu.edu.cn.



李康 (1981-), 男, 讲师, 研究方向: 模式识别和智能处理。

