

文章编号 1004-924X(2011)09-2205-09

用于分类的样本保局鉴别分析方法

杨利平*, 辜小花, 叶洪伟

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400044)

摘要:针对高维数据分类中鉴别特征降维方法的小样本问题和有效维度丢失问题,结合最新提出的片对齐框架和保局投影提出了样本保局鉴别分析方法。该方法通过分别构造每个样本的类内近邻图和类外近邻图,并将所有样本的类内近邻图和类外近邻图结合起来,形成了所有样本的类内近邻和类外近邻关系。然后,在使所有样本的类内近邻尽可能地聚集在一起的同时使类外近邻尽可能地分开,得到从高维输入空间到低维特征空间的最优映射关系。该方法有效避免了高维数据分类的小样本问题且扩展了鉴别分析的低维特征空间的有效维度。在 ORL、FERET 和 PIE 等人脸库上的高维数据分类实验证实,样本保局鉴别分析方法显著优于经典的鉴别特征降维方法。与基于片对齐框架提出的鉴别局部对齐方法相比,样本保局鉴别分析方法在 FERET 库上的分类识别精度提高了 4.5% 以上。

关键词:保局投影;鉴别分析;降维;模式分类

中图分类号: TP391.41 **文献标识码:** A **doi:** 10.3788/OPE.20111909.2205

Sample locality preserving discriminant analysis for classification

YANG Li-ping*, GU Xiao-hua, YE Hong-wei

(Laboratory of Optoelectronic Technology and Systems of the Ministry of Education,
Chongqing University, Chongqing 400044, China)

* Corresponding author, E-mail: yanglp@cqu.edu.cn

Abstract: The small sample size and the loss of effective dimension problems always exist in discriminative dimension reduction methods of high-dimensional data classification. To address these problems, a Sample Locality Preserving Discriminant Analysis (SLPDA) method is proposed by integrating the latest patch alignment framework and Locality Preserving Projections (LPP). The within-class and out-class neighborhood relationships of all samples in the SLPDA are constructed by summing the within-class and out-class neighborhood graphs of each sample, respectively. Thereafter, the optimal mapping from a high-dimensional input space to a low-dimensional feature space of the SLPDA is obtained by making the within-class neighbors of all samples as close as possible and meanwhile keeping the out-class neighbors as distant as possible. The proposed SLPDA method avoids the small sample size problem of high-dimensional data classification and extends the effective dimension of low-dimensional feature space. Experimental results on several high-dimensional face databases, e. g. ORL, FERET and PIE, indicate that the proposed SLPDA method significantly outperforms the classical discriminative dimension reduction methods. Comparing with Discriminative Locality Alignment

收稿日期: 2011-01-06; **修订日期:** 2011-02-27.

基金项目: 中央高校基本科研业务费科研专项项目 (No. CDJZR10120010); 高等学校博士学科点专项科研基金资助项目 (No. 20100191120012)

(DLA), which is also a dimension reduction method based on patch alignment framework, the recognition rate of SLPDA on a FERET subset is 4.5% higher.

Key words: locality preserving projection; discriminant analysis; dimension reduction; pattern classification

1 引言

在模式分类、机器学习和计算机视觉等研究领域,由于摄像机获取到的图像数据往往是高维的,直接对其进行处理将非常耗时,且不能得到理想的结果^[1-2],因此,需要利用子空间学习方法对数据进行降维,以挖掘其本质特征。子空间特征降维方法的基本思想:对给定的数据集,寻找一种从高维数据空间到低维特征空间的映射,使得通过该映射能得到数据集的一种可靠的低维特征描述。

近年来,基于图嵌套的子空间特征降维方法已经被成功地应用到模式分类中,并成为机器学习和模式分类中一类非常重要的方法^[3]。在这些方法中,具有代表性的是流形嵌套方法,如等距映射(Isometric Mapping, ISOMAP)^[4]、局部线性嵌入(Local Linear Embedding, LLE)^[5]、拉普拉斯特征映射(Laplacian Eigenmaps, LE)^[6]和保局投影(Locality Preserving Projections, LPP)^[7-8]等。事实上,许多经典的子空间特征降维方法,如主成分分析(Principal Component Analysis, PCA)^[9]和线性鉴别分析(Linear Discriminant Analysis, LDA)^[10],也可以用图嵌套框架来解释。这些方法的本质差异在于它们的图构造过程。因此,图的构造成为当前子空间降维方法的研究重点。

拉普拉斯特征映射^[6]及其线性近似——保局投影^[7]方法通过寻找各样本的 k 近邻样本建立了所有样本及其 k 近邻之间的一种近邻图,并在保持这种近邻关系的约束下获得了样本从高维输入空间到低维特征空间的投影关系,使得在高维输入空间互为近邻的样本投影后在低维特征空间中仍互为近邻。局部线性嵌入^[5]及其线性近似方法——近邻保持嵌入(Neighborhood Preserving Embedding, NPE)方法^[11]则假设样本可以由其 k 个近邻来重建且重建系数在高维输入空间和低

维特征空间是保持不变的,由此获得了样本的近邻图和高维空间到低维空间的映射关系^[12]。

上述方法对于描述样本集的本质几何特性是非常有效的。但对于模式分类而言,由于忽略了样本的类别信息,这些方法获得的特征鉴别能力有限。大量的文献已经证实^[13-17],在构造流形嵌套的近邻图时同时考虑样本的近邻信息和样本的类别信息是一种提高流形子空间特征降维方法分类性能的有效途径。这类方法的核心思想是通过分别构建样本的类内近邻图和类间近邻图来描述样本的类内差异和类间差异,然后利用鉴别分析方法获得最优的投影矩阵。代表性的方法有:Yu等结合 Fisher 线性鉴别分析和 LPP 提出的鉴别保局投影方法(Discriminant Locality Preserving Projections, DLPP)^[16],Hu 提出的正交近邻保持鉴别分析方法(Orthogonal Neighborhood Preserving Discriminant Analysis, ONPDA)^[15]和 Zhang 等提出的鉴别正交保近邻投影(Discriminative Orthogonal Neighborhood Preserving Projections, DONPP)^[13]等。在前期研究中,作者从子空间分析的角度对鉴别保局投影进行了探讨,提出了零空间鉴别保局投影方法^[18](Null-space DLPP, NDLPP)和完备鉴别保局投影(Complete DLPP, CDLPP)方法^[17],并通过实验证实了它们对分类问题的有效性。然而,当对高维小样本数据进行降维时,上述方法仍然存在问题,具体表现在:(1)由于小样本问题的存在,使 DLPP、ONPDA 和 NDLPP 等算法的性能受到限制;(2)对于一个 C 类分类问题而言,DLPP、ONPDA 和 NDLPP 算法得到的特征维度最多只有 $C-1$ 维,由于特征维度有限,可能会造成有效维度丢失,使在原始空间中靠的较近的两类经投影后重合起来,无法分开^[19]。

本文针对 DLPP、ONPDA 和 NDLPP 等算法的缺陷,从对 DLPP 算法的分析入手,提出一种样本保局鉴别分析(Sample Locality Preserving Discriminant Analysis, SLPDA)方法。该方法结

合文献[12]提出的“片对齐”框架,以样本为中心,通过构造每个样本的类内近邻图和类外近邻图,进而形成所有样本的类内近邻图和类外近邻图。通过使样本的类内近邻尽可能地聚集在一起的同时,使类外近邻尽可能地分开得到从高维输入空间到低维特征空间的映射关系。该方法可以避免高维数据分类的小样本问题,同时可增加有效特征的维数,增强特征的鉴别能力。在 ORL、FERET 和 PIE 等人脸图像库上的识别实验证实了样本保局鉴别分析方法对高维数据分类的有效性。

2 鉴别保局投影

给定来自 C 个类别 $\{\omega_1, \omega_2, \dots, \omega_C\}$ 的训练样本集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, 其中 $\mathbf{x}_i \in \mathbf{R}^m (i=1, 2, \dots, N)$, 鉴别保局投影通过在最大化保局类间散布的同时最小化保局类内散布获得最优的投影矩阵 Φ , 其中保局类间散布定义为:

$$\mathbf{S}_b^l = \sum_{c_i=1}^C \sum_{c_j=1}^C (\bar{\mathbf{x}}_{c_i} - \bar{\mathbf{x}}_{c_j}) \omega_{c_i c_j} (\bar{\mathbf{x}}_{c_i} - \bar{\mathbf{x}}_{c_j})^T, \quad (1)$$

保局类内散布定义为:

$$\mathbf{S}_w^l = \sum_{c=1}^C \sum_{x_i, x_j \in \omega_c} (\mathbf{x}_i - \mathbf{x}_j) \omega_{ij}^{(c)} (\mathbf{x}_i - \mathbf{x}_j)^T, \quad (2)$$

式中 $\bar{\mathbf{x}}_{c_i}$ 表示 ω_{c_i} 类的均值, 即: $\bar{\mathbf{x}}_{c_i} = (1/N_{c_i}) \sum_{j=1}^{N_{c_i}} \mathbf{x}_j$, N_{c_i} 为 ω_{c_i} 类的样本数; $\omega_{c_i c_j}$ 为 ω_{c_i} 类和 ω_{c_j} 类的均值 $\bar{\mathbf{x}}_{c_i}$ 和 $\bar{\mathbf{x}}_{c_j}$ 之间的权重, $\omega_{ij}^{(c)}$ 为 ω_c 类的样本 \mathbf{x}_i 和 \mathbf{x}_j 之间的权重, 它们的定义分别为:

$$\omega_{c_i c_j} = \begin{cases} \exp\left(-\frac{\|\bar{\mathbf{x}}_{c_i} - \bar{\mathbf{x}}_{c_j}\|^2}{2\sigma^2}\right), & \bar{\mathbf{x}}_{c_i} \text{ 和 } \bar{\mathbf{x}}_{c_j} \text{ 互为 } k \text{ 近邻} \\ 0, & \text{otherwise} \end{cases}, \quad (3)$$

$$\omega_{ij}^{(c)} = \begin{cases} \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right), & \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 互为 } k \text{ 近邻,} \\ & \text{且 } \mathbf{x}_i, \mathbf{x}_j \in \omega_c \\ 0, & \text{otherwise} \end{cases}, \quad (4)$$

其中, σ 为经验参数。

这样, DLPP 的最优投影矩阵可以通过求解以下最大化问题得到:

$$\Phi^* = \arg \max_{\Phi} \frac{\text{tr}(\Phi^T \mathbf{S}_b^l \Phi)}{\text{tr}(\Phi^T \mathbf{S}_w^l \Phi)}, \quad (5)$$

数学上, 最大化问题(5)等价于求解矩阵 $(\mathbf{S}_w^l)^{-1} \mathbf{S}_b^l$ 的前 d 个最大特征值对应的特征向量。

但是, 从上述的 DLPP 最优投影矩阵计算过程中不难看出, DLPP 有以下的缺陷: (1) 由于保局类间散布矩阵 \mathbf{S}_b^l 的秩最大只能是 $C-1$, 因此由 DLPP 得到的特征维度上限为 $C-1$ 。这一限制可能会造成在原始空间中靠的较近的两类经投影后重合起来无法分开, 使得 DLPP 的分类性能降低。(2) DLPP 利用各类样本均值的散布来描述保局类间散布 \mathbf{S}_b^l , 无法有效地包含各类的边界信息。然而, 对模式分类方法而言, 各类边界的可分性将直接影响分类性能的好坏。(3) 对于高维数据分类而言, 由于小样本问题的存在, DLPP 无法直接计算保局类内散布矩阵 \mathbf{S}_w^l 的逆。

3 样本保局鉴别分析

针对 DLPP 算法的缺陷, 本文以样本为中心, 从分析样本的类内近邻和类外近邻出发, 提出了样本保局鉴别分析方法。对给定的来自 $\{\omega_1, \omega_2, \dots, \omega_C\}$ 的训练样本集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, $\mathbf{x}_i \in \mathbf{R}^m (i=1, 2, \dots, N)$ 中的任意一个样本 \mathbf{x}_i , 分别选择该样本的 $l (l < N_c, N_c$ 为 ω_c 类的样本数) 个类内近邻样本 $\mathbf{x}_i^1, \dots, \mathbf{x}_i^l$ 和 k 个类外近邻样本 $\mathbf{x}_{i_1}, \dots, \mathbf{x}_{i_k}$, 这样, 对于任一样本 \mathbf{x}_i , 都可获得表征其类内近邻和类外近邻的子集 $\mathbf{X}_i = [\mathbf{x}_i, \mathbf{x}_i^1, \dots, \mathbf{x}_i^l, \mathbf{x}_{i_1}, \dots, \mathbf{x}_{i_k}]$ 。样本保局鉴别分析的目的是: 对于任一样本 \mathbf{x}_i , 在保持子集 \mathbf{X}_i 中样本的局部近邻关系的前提下, 使 \mathbf{x}_i 投影后与子集内的类内近邻尽可能地聚集在一起, 同时与子集内的类外近邻尽可能地分开。

设 $\mathbf{Y}_i = [\mathbf{y}_i, \mathbf{y}_i^1, \dots, \mathbf{y}_i^l, \mathbf{y}_{i_1}, \dots, \mathbf{y}_{i_k}] \in \mathbf{R}^{d \times (l+k+1)} (d \ll m)$ 为 \mathbf{X}_i 在低维特征空间的投影, 则对于任一样本 \mathbf{x}_i , 样本保局鉴别分析要求样本 \mathbf{x}_i 投影后的 \mathbf{y}_i 与其类内近邻 $\mathbf{y}_i^1, \dots, \mathbf{y}_i^l$ 尽可能地聚集在一起, 同时 \mathbf{y}_i 与其类外近邻 $\mathbf{y}_{i_1}, \dots, \mathbf{y}_{i_k}$ 尽可能地分开, 即同时满足下列最优化问题:

$$\min \text{trace} \left(\sum_{j=1}^l (\mathbf{y}_i - \mathbf{y}_i^j) \omega_{ij} (\mathbf{y}_i - \mathbf{y}_i^j)^T \right), \quad (6)$$

$$\min \text{trace} \left(\sum_{j=1}^k (\mathbf{y}_i - \mathbf{y}_{i_j}) \omega_{ij} (\mathbf{y}_i - \mathbf{y}_{i_j})^T \right), \quad (7)$$

其中, w_{j^l} 为 y_i 与其类内第 j 个近邻的权重, w_{i_j} 为 y_i 与其类外第 j 个近邻的权重。因样本保局鉴别分析在投影前后保持了样本与其类内近邻和类间近邻样本的近邻关系, 所以可以假设样本投影前后的权重不变, 即 $w_{j^l} = \exp(-\|x_i - x_{j^l}\|^2 / 2\sigma^2)$, $w_{i_j} = \exp(-\|x_i - x_{i_j}\|^2 / 2\sigma^2)$, 其中, σ 为经验参数。

令 $w_i^{\text{In}} = \text{diag}[w_{i_1}, w_{i_2}, \dots, w_{i_l}]$, $w_i^{\text{Out}} = \text{diag}[w_{i_1}, w_{i_2}, \dots, w_{i_k}]$, 则式(6)和(7)可分别化为:

$$\min_{\Phi} \text{trace} \left(Y_i \begin{bmatrix} -e_l \\ w_i^{\text{In}} \\ z_{k \times l} \end{bmatrix} \begin{bmatrix} -e_l^T & I_l & z_{k \times l}^T \end{bmatrix} Y_i^T \right) = \min_{\Phi} \text{trace}(Y_i L_i^{\text{In}} Y_i^T), \quad (8)$$

$$\max_{\Phi} \text{trace} \left(Y_i \begin{bmatrix} -e_k \\ z_{k \times l} \\ w_i^{\text{Out}} \end{bmatrix} \begin{bmatrix} -e_k & z_{k \times l}^T & I_k \end{bmatrix} Y_i^T \right) = \max_{\Phi} \text{trace}(Y_i L_i^{\text{Out}} Y_i^T), \quad (9)$$

其中,

$$L_i^{\text{In}} = \begin{bmatrix} l & -e_l & z_{1 \times k} \\ -w_i^{\text{In}} e_l^T & w_i^{\text{In}} & z_{l \times k} \\ z_{k \times 1} & z_{k \times l} & z_{k \times k} \end{bmatrix}, \quad (10)$$

$$L_i^{\text{Out}} = \begin{bmatrix} k & z_{1 \times l} & -e_k \\ z_{l \times 1} & z_{l \times l} & z_{l \times k} \\ -w_i^{\text{Out}} e_k^T & z_{k \times l} & w_i^{\text{Out}} \end{bmatrix}, \quad (11)$$

且 $z_{k \times l}$ 为 $k \times l$ 的全 0 矩阵, e_l 为 l 维的全 1 行向量, I_l 为 $l \times l$ 的单位阵。于是, 对于任一 x_i , 样本保局鉴别分析需要同时考虑(8)和(9)两个最优化问题。将二者结合起来, 可以考虑以下最优化问题:

$$\min_{\Phi} \text{trace}(Y_i (L_i^{\text{In}} - \beta L_i^{\text{Out}}) Y_i^T) = \min_{\Phi} \text{trace}(\Phi^T X_i L_i X_i^T \Phi), \quad (12)$$

其中, $L_i = L_i^{\text{In}} - \beta L_i^{\text{Out}}$, $\beta \in [0, 1]$ 为尺度因子, 用以统一子集中类内近邻和类间近邻的度量。

对于每一个由样本 x_i 和其类内近邻及类外近邻构成的子集 X_i , 由于构成子集的所有样本都来自于训练样本集 X , 所以可以将 X_i 表示为:

$$X_i = X S_i, \quad (13)$$

其中, $S_i \in \mathbf{R}^{N \times (l+k+1)}$ 为选择矩阵, 其元素的取值为:

$$(S_i)_{pq} = \begin{cases} 1, & \text{当 } p = (F_i)_q \text{ 时} \\ 0, & \text{otherwise} \end{cases}, \quad (14)$$

其中 $F_i = \{i, i^1, \dots, i^l, i_1, \dots, i_k\}$ 表示构成子集 X_i 的各样本在训练样本集 X 中的索引值。这样, 最优化问题(12)可进一步转化为:

$$\min_{\Phi} \text{trace}(\Phi^T X S_i L_i S_i^T X^T \Phi). \quad (15)$$

考虑到样本保局鉴别分析要求训练集中的任一样本 x_i 都满足式(15)的最优化问题, 这里对所有样本的子集优化问题进行求和, 得到:

$$\begin{aligned} \min \sum_{i=1}^N \text{trace}(\Phi^T X S_i L_i S_i^T X^T \Phi) &= \\ \min_{\Phi} \text{trace}(\Phi^T X (\sum_{i=1}^N S_i L_i S_i^T) X^T \Phi) &= \\ \min_{\Phi} \text{trace}(\Phi^T X L X^T \Phi), \end{aligned} \quad (16)$$

其中 $L = \sum_{i=1}^N S_i L_i S_i^T \in \mathbf{R}^{N \times N}$ 称为对齐矩阵^[12]。因此, 样本保局鉴别分析的最优映射矩阵 Φ^* 可通过求解式(16)的最优化问题得到, 即:

$$\Phi^* = \arg \min_{\Phi} \text{trace}(\Phi^T X L X^T \Phi). \quad (17)$$

为了使获得的最优映射的各列相互正交, 可在求解式(17)时增加约束条件 $\Phi^T \Phi = I_d$, 其中 I_d 为单位阵。显然, 式(17)的解为特征值问题 $X L X^T \Phi = \lambda \Phi$ 的前 d 个最小特征值对应的特征向量。

从上述的分析和推导过程中不难看出样本保局鉴别分析方法具有以下特点:(1)样本保局鉴别分析不需要计算矩阵的逆, 可以克服高维数据投影时的小样本问题;(2)样本保局鉴别分析中的对齐矩阵 L 通常是满秩的, 因此, 获得的特征维度上限可达 $N-1$;(3)样本保局鉴别分析方法的子集优化过程同时选择了样本的类内近邻和类外近邻, 而类外近邻往往都是分布在其他类边界上的一些样本点, 也就是说, 该方法在计算最优映射矩阵时充分考虑了各类的边界样本。

4 实验结果与分析

本节利用国际通用的 ORL、FERET 和 PIE 等人脸图像库, 对提出的样本保局鉴别分析方法和 LDA^[10]、DLPP^[16]、NDLPP^[18]、DLA^[12] 等几种有监督特征降维方法在高维数据分类中的性能进

行比较。对于 ORL 这样的小型人脸库,利用了来自 40 人的共 400 幅人脸图像进行实验。对于 FERET 和 PIE 两个大型的人脸图像库,选择了其中的正面人脸图像构成两个子库进行实验,在 FERET 库中,选择了来自 229 个个体的 1 131 幅正面人脸图像(每个个体至少有 4 幅图像)构成 FERET 子库;在 PIE 库中,选择了 68 个个体在不同光照下的 1 425 幅正面人脸图像构成 PIE 子库。3 个人脸图像库的所有图像均根据眼睛坐标进行旋转、剪切、缩放到大小为 32 pixel×32 pixel 的图像,未做任何其它处理。图 1 显示了各人脸图像库的图像示例。

在实验中,人脸图像库被随机地分为训练集和测试集两部分。训练集用来训练上述 5 种方法的最优投影矩阵,测试集则用来计算各种方法的识别精度。由于样本数远小于样本的维度,在利用上述 5 种特征降维方法进行特征提取前都先利用 PCA 对样本进行了降维处理。在计算识别精度时,本文使用了最简单的最近邻分类器。




(a) ORL 库

(a) ORL



(b) FERET 库

(b) FERET



(c) PIE 库

(c) PIE

图 1 ORL、FERET 和 PIE 人脸图像库中的人脸图像
Fig. 1 Face samples from ORL, FERET and PIE face databases

4.1 SLPDA 的参数选择实验

在样本保局鉴别分析方法中,类内近邻数 l 和类外近邻数 k 是两个重要的参数。这里通过在 ORL 人脸图像库上的实验来讨论 l 和 k 的选择对识别精度的影响。选择每类 7 个样本构成训练集,剩余的每类 3 个样本构成测试集。先固定类外近邻数 k 为任一值(实验中取 $k=1$)来考察识别精度随类内近邻数 l 的变化情况。图 2(a)给出了类内近邻数从 1 到 $N_c-1(=6)$ 变化时的识别精度曲线。可以看出,随着类内近邻数的增大,识别精度也逐步增大。接下来,固定 $l=6$ 来考察识别精度随类外近邻数 k 的变化情况。图 2(b)给出了类外近邻数从 1 到 50 变化时的识别精度曲线。可以看出,当 k 的取值较小时,得到了较高的识别精度。上述实验结果说明:尽可能地保持样本类内的近邻关系可以提高其分类能力,然而过分强调样本的类外近邻关系则不利于样本的分类。

另外,本文在 FERET 和 PIE 两个子库上也进行了相同的实验,结果与 ORL 库上的一致,都是在类内近邻数 N_c-1 为且类外近邻数取较小的值时取得了最高的识别精度。因此,在后续试验中,取类内近邻数为 $l=N_c-1$,类外近邻数 $k=1$ 。

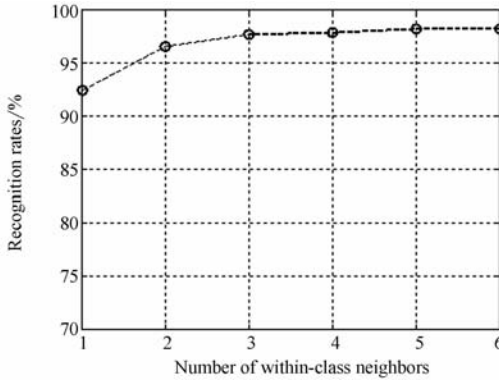
4.2 几种方法的性能比较结果及讨论

为了验证样本保局鉴别分析方法的分类性能,本文分别在 ORL 库、FERET 子库和 PIE 子库上比较了 LDA、DLPP、NDLPP、DLA 和 SLPDA 等方法的识别精度。

在每个库上,随机选择不同数量的个体样本作为训练样本,剩余的其他样本作为测试样本进行实验。每种方法的结果都是由 10 次独立实验的结果取平均得到的。图 3 给出了 FERET 子库上训练样本数分别为 2 和 3 时,5 种方法的平均识别精度随特征维度的变化关系。表 1~表 3 给出了 3 个图像库上,不同数目训练样本条件下,每种方法的最佳识别精度比较。

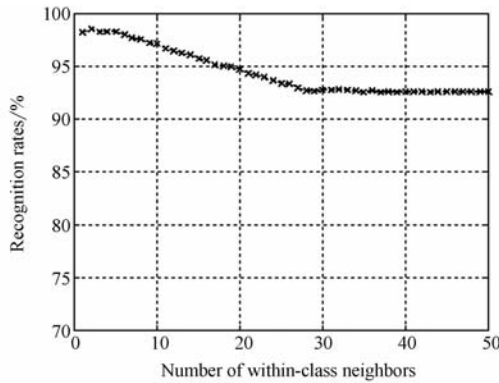
从上面的实验结果可以看出:(1)表 1~表 3 显示的结果表明:尽管在 ORL 库中,当训练样本数分别为 2 和 7 时,SLPDA 方法的分类识别性能

不是最高的,但与 NDLPP 和 DLA 两种取得了最高识别精度的方法相比,SLPDA 方法的性能与之相当;在其他所有情况下,本文提出的 SLPDA 方法均获得了最高的识别精度,可见 SLPDA 方法的分类识别性能是 5 种方法中最优的。(2)SLPDA 和 DLA 两种基于片对齐框架的方法的分类精度显著优于 LDA 和 DLPP 两种经典的数据降维方法。(3)和 DLA 方法相比,SLPDA 由于考虑了样本的局部近邻之间的权重而得到了更优的分类识别性能。如表 2 所示,在 FERET 子库上,SLPDA 方法的平均识别精度比 DLA 方法高 4.5%



(a) 识别精度与类内近邻数 l 的关系曲线

(a) Recognition rates versus number of within-class neighbors




(b) 识别精度与类外近邻数 k 的关系曲线

(b) Recognition rates versus number of out-class neighbors

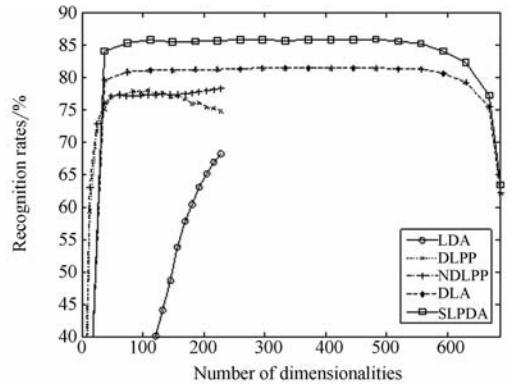
图 2 ORL 库上识别精度与近邻数的关系(训练样本数为 7)

Fig. 2 Relationship between recognition rates and number of neighbors on ORL database (with number of training samples of 7)



(a) 2 个训练样本

(a) Two training samples



(b) 3 个训练样本

(b) Three training samples

图 3 FERET 子集上识别精度随特征维度的变化情况

Fig. 3 Recognition rates versus number of dimensionalities on FERET subset

以上。(4)与 DLPP 方法相比,SLPDA 由于用样本的类外近邻代替了 DLPP 中的类间近邻而使特征的维数增大,显著增强了特征的鉴别能力。如在表 2 中,当训练样本为 3 时,SLPDA 方法的平均分类识别精度比 DLPP 方法高 7.7%。(5)从图 3 观察到一个有趣的现象,随着特征维度的增加,SLPDA 方法的识别精度会逐步增大并趋于稳定,但当特征维度增大到一定程度时,识别精度则会急剧下降。这是由于 SLPDA 降维方法的有效维度取决于式 (17) 中矩阵的秩,而该矩阵 XLX^T 的秩则与训练样本的数量及它们之间的局部近邻关系有关。

表1 ORL库上5种特征降维方法的最佳分类识别精度比较(%)

Tab.1 Best recognition rates of five dimensionality reduction methods on ORL database(%)

训练样本数	LDA	DLPP	NDLPP	DLA	SLPDA
2	75.6±2.93	64.9±2.34	83.2±2.21	81.6±2.97	82.8±1.78
3	87.4±1.32	84.3±1.54	91.3±1.46	91.0±2.73	92.1±1.27
4	90.8±2.07	91.6±2.36	94.8±1.79	94.8±1.73	95.8±1.73
5	93.1±1.61	93.9±1.72	95.5±1.21	96.6±1.51	97.1±1.40
6	95.8±1.99	96.2±2.05	97.5±1.02	98.4±1.03	98.7±0.80
7	95.9±1.78	97.3±0.86	98.0±1.25	98.7±1.37	98.5±0.95
8	96.6±1.67	98.6±0.71	98.6±0.71	98.8±1.18	99.3±0.65

表2 FERET子库上5种特征降维方法的最佳分类识别精度比较(%)

Tab.2 Best recognition rates of five dimensionality reduction methods on FERET subset(%)

训练样本数	LDA	DLPP	NDLPP	DLA	SLPDA
2	61.9±1.21	68.8±2.05	71.0±1.47	67.6±1.54	72.6±2.36
3	68.2±1.92	78.0±2.11	78.3±2.19	81.5±0.76	86.0±1.02

表3 PIE子库上5种特征降维方法的最佳分类识别精度比较(%)

Tab.3 Best recognition rates of five dimensionality reduction methods on PIE subset(%)

训练样本数	LDA	DLPP	NDLPP	DLA	SLPDA
2	75.6±1.91	68.5±2.49	77.6±1.50	76.1±1.82	79.2±1.59
4	90.7±1.30	89.0±1.72	90.7±1.38	93.3±1.16	93.7±1.13
6	97.2±1.20	96.1±1.54	96.7±1.47	97.5±0.65	98.1±0.97
8	98.5±0.71	98.4±0.82	98.4±0.80	99.1±0.65	99.3±0.58
10	99.4±0.30	99.4±0.33	99.2±0.42	99.8±0.20	99.8±0.20

5 结 论

本文针对高维数据分类中经典鉴别特征降维方法的小样本问题和有效特征维度丢失的问题,结合片对齐框架提出了样本保局鉴别分析方法。文章分析了经典的鉴别保局投影特征降维方法的缺陷,介绍了样本保局鉴别分析方法的基本原理

及实现方法,并以人脸识别为例进行了大量的分类实验。实验结果表明,样本保局鉴别分析方法的分类识别精度优于当前一些主要的特征降维方法。在FERET人脸库上的实验显示,样本保局鉴别分析方法的平均识别精度比DLA方法高4.5%以上,比经典的DLPP方法高7.7%,充分证实了样本保局鉴别分析方法的有效性。

参考文献:

- [1] 梁毅雄, 龚卫国, 潘英俊, 等. 基于奇异值分解的人脸识别方法[J]. 光学精密工程, 2004, 12(5): 543-549.
LIANG Y X, GONG W G, PAN Y J, *et al.*. Singular value decomposition-based approach for face recognition [J]. *Opt. Precision Eng.*, 2004, 12(5): 544-549. (in Chinese)

- [2] 黄鸿, 李见为, 冯海亮. 基于有监督的核局部线性嵌入的面部表情识别[J]. 光学精密工程, 2008, 16(8): 1471-1477.
HUANG H, LI J W, FENG H L. Facial expression recognition based on supervised kernel local linear embedding [J]. *Opt. Precision Eng.*, 2008, 16(8): 1471-1477. (in Chinese)
- [3] YAN S C, XU D, ZHANG B Y, *et al.*. Graph embedding and extensions: a general framework for di-

- mensionality reduction [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(1):40-51.
- [4] TENENBAUM J B, SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(22):2319-2323.
- [5] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(22):2323-2326.
- [6] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6):1373-1396.
- [7] 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.
- [8] 杨利平, 龚卫国, 李伟红, 等. 随机采样子空间保局投影人脸识别算法[J]. *光学精密工程*, 2008, 16(8):1465-1470.
- YANG L P, GONG W G, LI W H, *et al.*. Random sampling subspaces locality preserving projections for face recognition [J]. *Opt. Precision Eng.*, 2008, 16(8):1465-1470. (in Chinese)
- [9] TURK M, PENTLAND A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1):71-86.
- [10] BELHUMEUR P N, HESPANHA J P, KRIEGMAN D J. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7):711-720.
- [11] HE X F, CAI D, YAN S C, *et al.*. Neighborhood preserving embedding [C]. *Proceedings of IEEE International Conference on Computer Vision*, 2005, 1208-1213.
- [12] ZHANG T H, TAO D C, LI X L, *et al.*. Patch alignment for dimensionality reduction [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(9):1299-1313.
- [13] ZHANG T H, HUANG K Q, LI X L, *et al.*. Discriminative orthogonal neighborhood-preserving projections for classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*, 2010, 40(1):253-263.
- [14] YANG L P, GONG W G, GU X H, *et al.*. Bagging null space locality preserving discriminant classifiers for face recognition [J]. *Pattern Recognition*, 2009, 42(9):1853-1858.
- [15] HU H F. Orthogonal neighborhood preserving discriminant analysis for face recognition [J]. *Pattern Recognition*, 2008, 41(6):2045-2054.
- [16] 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.
- [17] 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 L P, GONG W G, GU X H, *et al.*. Complete discriminant locality preserving projections for face recognition [J]. *Journal of Software*, 2010, 21(6):1277-1286. (in Chinese)
- [18] YANG L P, GONG W G, GU X H, *et al.*. Null space discriminant locality preserving projections for face recognition [J]. *Neurocomputing*, 2008, 71(16-18):3644-3649.
- [19] LI Z F, LIN D H, TANG X O. Nonparametric discriminant analysis for face recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(4):755-761.

作者简介:



杨利平(1981—),男,内蒙古鄂尔多斯人,讲师,博士,2008年于重庆大学获工学博士学位,主要从事图像处理、模式识别等方面的研究。E-mail: yanglp@cqu.edu.cn



叶洪伟(1987—),男,重庆垫江人,硕士研究生,2010年于重庆理工大学获工学学士学位,主要从事模式识别方面的研究。E-mail: 20100802067@cqu.edu.cn



辜小花(1982—),女,四川仁寿人,博士研究生,2005年于重庆大学获得学士学位,主要从事模式识别、图像处理方面的研究。E-mail: xhgu@cqu.edu.cn

● 下期预告

纳米压印 DFB 光栅模板制作技术

王定理^{1,3},刘 文^{1,2,3},周 宁^{1,3},徐智谋²

(1. 武汉光迅科技股份有限公司,湖北 武汉 430074;

2. 华中科技大学 武汉光电国家实验室,湖北 武汉 430074;

3. 新一代光纤通信技术和网络国家重点实验室,湖北 武汉 430074)

压印模板的制作技术是采用纳米压印制作 DFB 光栅的重要研究课题之一。本文采用双层金属掩模及 lift-off 金属剥离方法制作了适用于紫外压印技术的石英基压印模板。首先采用电子束光刻技术在镀钛的石英基片表面直写出 DFB 光栅的光刻胶图形,接着在其表面溅射一层金属镍并进行金属剥离得到与光刻胶相对的图形,最后采用 ICP 干法刻蚀的技术将光栅图形转移到石英基片上,并对模板的表面进行了防粘连处理。所制作的 DFB 光栅压印模板周期为 200 nm,光栅中间具有 $\lambda/4$ 相移结构,适用于 1 310 nm 波长的相移型 DFB 半导体激光器光栅的制作。