

DOI: 10.7652/xjtuxb201606009

一种鉴别稀疏局部保持投影的人脸识别算法

杨艺芳^{1,3}, 王宇平²

(1. 西安电子科技大学数学与统计学院, 710071, 西安; 2. 西安电子科技大学计算机学院, 710071, 西安;
3. 西安石油大学理学院, 710065, 西安)

摘要: 为解决鉴别稀疏邻域保持嵌入(DSNPE)算法中类间离散度构造复杂的问题,提出了一个新的维数约简算法即鉴别稀疏局部保持投影的人脸识别算法(DSLPP)。首先利用样本集中各类样本的平均向量构造字典,通过保持各类样本平均向量的稀疏重构关系,提出一个新的无参数类间离散度;再通过同时最大化类间离散度和同时最小化类内紧凑度的准则来寻找最优投影方向;最后采用最近邻分类器进行人脸分类识别。由于所采用的类间离散度最大限度地扩大了不同类别中样本之间的差异,因此 DSLPP 算法具有更强的类间判别力,其识别率得到了明显提高;此外,字典的简化构造降低了算法的计算复杂度。在 Yale、UMIST 和 AR 人脸库上的实验结果表明:DSLPP 算法在 Yale、UMIST 库上的平均识别率及 AR 库上的最高识别率分别达 83.38%、95.72% 和 83.71%,较其他传统方法的识别率有明显提高;在 UMIST 库上的实验结果表明,DSLPP 算法较 DSNPE 算法的平均计算时间减少了 81.7%。

关键词: 人脸识别;维数约简;稀疏重构;局部保持投影

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 0253-987X(2016)06-0054-07

A Face Recognition Algorithm Based on Discriminant Sparse Locality and Preserving Projections

YANG Yifang^{1,3}, WANG Yuping²

(1. School of Mathematics and Statistics, Xidian University, Xi'an 710071, China; 2. School of Computer Science and Technology, Xidian University, Xi'an 710071, China; 3. College of Science, Xi'an Shiyong University, Xi'an 710065, China)

Abstract: A new face recognition algorithm, i. e. a discriminant sparse locality and preserving projection algorithm (DSLPP), is proposed to solve the problem that the construction between-class scatters is too complex in the discriminant sparse neighborhood and preserving embedding (DSNPE) method. A novel between-class scatter is constructed by using the mean vector of each class as dictionary and preserving the sparse reconstructive relationship of mean face. Then, an optimal projection matrix is obtained by maximizing the between-class scatter and minimizing the within-class compactness simultaneously. The nearest neighbor classifier is finally used for face recognition. The proposed between-class scatter maximizes the difference of samples between different classes and has more discriminant power, so that the recognition rate of the proposed algorithm is markedly improved. Moreover, the computational complex of the DSLPP algorithm is reduced because of the simple design of the dictionary. Experimental results show that the

收稿日期: 2015-11-19。 作者简介: 杨艺芳(1976—),女,博士生;王宇平(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(61503082,61472297)。

网络出版时间: 2016-04-03

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20160403.1823.008.html>

DSLPP algorithm achieves average recognition rates 83.38% and 95.72% on Yale, and UMIST face database respectively, and a maximal recognition rate 83.71% on AR face database, and that the recognition rates are obviously higher than the recognition rates of some conventional methods. The experimental results on UMIST face databases also show that the average computation time of the DSLPP algorithm is less 81.7% than that of the DSNPE algorithm.

Keywords: face recognition; dimension reduction; sparse reconstructive; local preserving projections

人脸识别中,往往会遇到“维数灾难”问题,因此维数约简是一种常采用的手段。目前,已经有许多种维数约简方法,根据不同的标准可以有不同的分类,根据映射函数的形式可分为线性和非线性。主成分分析(PCA)法^[1]和线性判别分析(LDA)法^[2]因其简单高效而成为经典算法,但是PCA和LDA算法都是基于欧氏空间的,主要用于处理线性数据集,不能发现复杂非线性数据集的固有结构。为刻画样本的非线性流形结构,一些能够处理非线性数据集的流形学习算法被相继提出,如等距映射(Iso-map)法^[3]、拉普拉斯特征映射(LE)法^[4]等,但这类方法中非线性映射仅定义在训练集上,对于新的测试集却无法通过此映射降维到低维空间。流形学习方法的线性化能够解决这个问题,代表性的算法有邻域保持嵌入(NPE)法^[5]和局部保持投影(LPP)法^[6],然而,NPE和LPP法都是无监督算法,没有利用数据点的类判别信息。因此,许多有监督的流形学习算法相继涌现出来,如有鉴别局部保持投影(DLPP)^[7]等流形学习算法,然而此类算法的共同缺点是需要人工选择邻域大小参数和边权值参数,而且其性能对这些参数比较敏感。

近年来,基于稀疏表示的方法在人脸识别中得到了广泛应用。2009年,Wright^[8]等人提出了基于稀疏表示分类器的人脸识别方法,将稀疏表示成功引入人脸识别领域。随后文献^[9-10]也相继提出基于稀疏表示的人脸识别方法,文献^[10-11]利用稀疏表示的方法自适应构建 L_1 范数图,不需要任何其他模式参数。稀疏保留投影算法(SPP)^[12]是一种以保持数据的稀疏表示结构为目的的较好的维数约简方法,但它是无监督的,未利用类标信息。对此,文献^[13]通过利用类标信息对SPP进行了改进,提出鉴别稀疏邻域保持嵌入的算法(DSNPE),获得了较高的人脸识别率,但DSNPE算法中类间离散度构造较复杂,尤其是稀疏表示字典包含数量很大的样本,时间复杂度较高。为了改进该算法的性能,本文提出了一个新的有监督的维数约简算法即鉴别稀疏

局部保持投影算法(DSLPP)。该算法用样本集中各类样本的平均向量构造字典,结合稀疏表示和DLPP算法中类间离散度的构造方法,提出新的无参数的类间离散度,有效降低了算法的计算复杂度,增强了算法的判别力。在常用的人脸数据集Yale、UMIST和AR上的测试结果表明,该算法相比其他算法具有更好的识别效果。

1 鉴别局部保持投影算法

给定一组训练样本 $\{\mathbf{x}_i\}_{i=1}^n$,其中 $\mathbf{x}_i \in \mathbf{R}^m$,则训练样本集可表示为 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_c] \in \mathbf{R}^{m \times n}$,其中 c 表示训练样本的类别数, $\mathbf{X}_i = [\mathbf{x}_{i,1}, \mathbf{x}_{i,2}, \dots, \mathbf{x}_{i,n_i}]$, n_i 表示第 i 类中样本的数。DLPP算法的目标函数为

$$\frac{\sum_{k=1}^c \sum_{i,j=1}^{n_k} (\mathbf{y}_i^k - \mathbf{y}_j^k) \mathbf{W}_{ij}^k}{\sum_{i,j=1}^c (\mathbf{m}_i - \mathbf{m}_j)^2 B_{ij}} \quad (1)$$

式中: $\mathbf{y}_i^k$ 表示映射空间中第 k 类的第 i 个向量; $\mathbf{m}_i$ 表示第 i 类的平均向量; $\mathbf{W}_{ij}^k$ 和 B_{ij} 分别为类内权重矩阵 $\mathbf{W}$ 和类间权重矩阵 $\mathbf{B}$ 的元素, $\mathbf{W}_{ij}^k$ 和 B_{ij} 分别通过式(1)、式(2)来确定

$$\mathbf{W}_{ij}^k = \exp(-\|\mathbf{x}_i^k - \mathbf{x}_j^k\|^2/t) \quad (2)$$

$$B_{ij} = \exp(-\|\mathbf{f}_i - \mathbf{f}_j\|^2/t) \quad (3)$$

式中: $\mathbf{f}_i = \frac{1}{n_i} \sum_{p=1}^{n_i} \mathbf{x}_p^i$; t 为高斯核函数的尺度参数。

DLPP算法的目标是最小化式(1)中的函数,从而求得最优投影矩阵。

2 鉴别稀疏邻域保持嵌入算法

DSNPE算法是通过最大化类内紧凑度和类间离散度之差来寻找最优投影矩阵。

2.1 类内紧凑度

对每一个训练样本 $\mathbf{x}_i$,用与 $\mathbf{x}_i$ 属于同一类的其他样本来重构 $\mathbf{x}_i$ 。假定 $\mathbf{x}_i$ 属于第 k 类(第 k 类有 n_k 个样本),与 $\mathbf{x}_i$ 相应的过完备字典 $\mathbf{D}_k$ 仅仅由与 $\mathbf{x}_i$

同类的其余样本组成。通过求解式(4)的 L_1 范数最小化问题,可以得到类内稀疏表示系数 s_i^w

$$\min_{s_i^w} \|s_i^w\|_1, \quad \text{s. t. } \|x_i - D_k s_i^w\|_2 < \varepsilon \quad (4)$$

式中: $D_k = [x_{k,1}, x_{k,2}, \dots, x_{k,i-1}, x_{k,i+1}, \dots, x_{k,n_k}] \in \mathbf{R}^{m \times n_k}$; $s_i^w = [s_{i,1}^w, s_{i,2}^w, \dots, s_{i,i-1}^w, 0, s_{i,i+1}^w, \dots, s_{i,n_k}^w]^T \in \mathbf{R}^{n_k}$; 上标 w 表示类内

类内权重矩阵 W^w 的元素 w_{ij}^w 定义如下

$$w_{ij}^w = \begin{cases} 0, & 1 \leq j \leq r_{k-1} \\ s_{i,j-r_{k-1}}^w, & r_{k-1} + 1 \leq j \leq r_{k-1} + n_k \\ 0, & r_k + 1 \leq j \leq n \end{cases} \quad (5)$$

式中: $r_{k-1} = n_1 + n_2 + \dots + n_{k-1}$ 。

通过定义下面的目标函数来构造类内紧凑度

$$\begin{aligned} \sum_{i=1}^n \left\| A^T x_i - \sum_{j=1}^n w_{ij}^w A^T x_j \right\|^2 = \\ A^T \sum_{i=1}^n \|x_i - X w_i^w\|^2 A = \\ A^T \left(\sum_{i=1}^n (x_i - X w_i^w)(x_i - X w_i^w)^T \right) A = \\ \text{tr}(A^T X M^w X^T A) \end{aligned} \quad (6)$$

式中: A 为投影矩阵; $M^w = (I - W^w)^T (I - W^w)$; w_i^w 是 W^w 的第 i 个列向量; $\text{tr}(A^T X M^w X^T A)$ 为类内紧凑度。

2.2 类间离散度

对每一个 x_i , 只需用与 x_i 不同类的样本来重构 x_i 。假定 x_i 属于第 k 类(第 k 类有 n_k 个样本), 与 x_i 相应的过完备字典 D^k 由与 x_i 不同类的其余样本组成。通过求解下面的 L_1 范数最小化问题, 可以得到类间稀疏表示系数 s_i^b

$$\min_{s_i^b} \|s_i^b\|_1, \quad \text{s. t. } \|x_i - D^k s_i^b\|_2 < \varepsilon \quad (7)$$

式中: $X^k = [X_1, X_2, \dots, X_{k-1}, X_{k+1}, \dots, X_c] \in \mathbf{R}^{m \times (n - n_k)}$; $s_i^b = [s_{i,1}^b, s_{i,2}^b, \dots, s_{i,n-n_k}^b]^T \in \mathbf{R}^{m \times (n - n_k)}$; 上标 b 指类间。

类间权重矩阵 W^b 的元素 w_{ij}^b 定义如下

$$w_{ij}^b = \begin{cases} s_{ij}^b, & 1 \leq j \leq r_{k-1} \\ 0, & r_{k-1} + 1 \leq j \leq r_{k-1} + n_k \\ s_{i,j-n_k}^b, & r_k + 1 \leq j \leq n \end{cases} \quad (8)$$

式中: $r_{k-1} = n_1 + n_2 + \dots + n_{k-1}$ 。

通过定义下面的目标函数来构造类间离散度

$$\begin{aligned} \sum_{i=1}^n \left\| A^T x_i - \sum_{j=1}^n w_{ij}^b A^T x_j \right\|^2 = \\ A^T \sum_{i=1}^n \|x_i - X w_i^b\|^2 A = \end{aligned}$$

$$A^T \left(\sum_{i=1}^n (x_i - X w_i^b)(x_i - X w_i^b)^T \right) A = \text{tr}(A^T X M^b X^T A) \quad (9)$$

式中: $M^b = (I - W^b)^T (I - W^b)$; w_i^b 是 W^b 的第 i 个列向量; $\text{tr}(A^T X M^b X^T A)$ 即为类间离散度。DSNPE 算法的最终目标为 $\max_A \text{tr}(A^T X L^b X^T A) - \mu \text{tr}(A^T X \cdot L^w X^T A)$ 。

3 鉴别稀疏局部保持投影算法

DSNPE 算法利用求得的稀疏表示系数创建 L_1 范数图, 其近邻参数可以通过稀疏约束自动产生, 从而克服了 NPE 算法中近邻参数设置难的问题, 但 DSNPE 算法的类间离散度构造较复杂。对此, 本文结合 LPP 算法, 通过最大化类间离散度和最小化类内紧凑度, 提出了 DSLPP 算法, 简化了类间离散度的构造, 扩大了不同类数据之间的距离, 增强了算法的判别力。

3.1 类内紧凑度

与 DSNPE 中类内紧凑度相同, W^w 表示类内权重矩阵。结合 LPP 算法, 定义类内紧凑度的目标函数为

$$\begin{aligned} \frac{1}{2} \sum_{i,j} \|y_i - y_j\|^2 w_{ij}^w = \\ \frac{1}{2} \sum_{i,j} \|A^T x_i - A^T x_j\|^2 w_{ij}^w = \\ \sum_{i,j} A^T x_i w_{ij}^w x_j^T A - \sum_{i,j} A^T x_i w_{ij}^w x_j^T A = \\ \text{tr}(A^T X L^w X^T A) \end{aligned} \quad (10)$$

式中: $L^w = D^w - W^w$; $D^w = \sum_j w_{ij}^w$; $\text{tr}(A^T X L^w X^T A)$ 为类内紧凑度。

3.2 本文提出的类间离散度

在 DLPP 算法中, 通过用不同类的均值向量之间的差异来刻画类间离散度, 从而大大提高了 DLPP 算法的类间判别力, 然而, 近邻个数和高斯核尺度等参数的敏感性严重影响了 DLPP 算法的性能。为此, 本文结合稀疏表示和 DLPP 算法的 Fisher 判别分析中的最大类间离散度的判别方法, 提出新的无参数的类间离散度。假定 f_i 和 f_j 分别表示第 i 类和第 j 类训练样本的均值向量, m_i 和 m_j 分别表示映射空间中第 i 类和第 j 类训练样本的均值向量。假定样本集一共 c 个类别, 类间稀疏表示系数 s_i^b 可以通过求解下面的 L_1 范数最小化问题得到

$$\min_{s_i^b} \|s_i^b\|_1, \quad \text{s. t. } \|x_i - D s_i^b\|_2 < \varepsilon \quad (11)$$

式中: $D = [f_1, f_2, \dots, f_{i-1}, f_i, f_{i+1}, \dots, f_c] \in \mathbf{R}^{m \times c}$;

$\mathbf{s}_i^b = [s_{i,1}^b, s_{i,2}^b, \dots, s_{i,c-1}^b]^T \in \mathbf{R}^{c-1}; \sum_j s_{i,j}^b = 1$.

本文提出的类间权重矩阵 $\mathbf{w}^b$ 的元素 w_{ij}^b 定义如下

$$w_{ij}^b = \begin{cases} s_{i,j}^b, & 1 \leq j \leq i-1 \\ 0, & j = i \\ s_{i,j-1}^b, & i+1 \leq j \leq c \end{cases} \quad (12)$$

式中: $\mathbf{W}^b$ 表示类间离散度矩阵。通过定义下面的目标函数来构造类间离散度

$$\begin{aligned} \frac{1}{2} \sum_{i,j=1}^c \|\mathbf{m}_i - \mathbf{m}_j\|^2 w_{ij}^b = \\ \frac{1}{2} \sum_{i,j=1}^c \left\| \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{y}_k^i - \frac{1}{n_j} \sum_{k=1}^{n_j} \mathbf{y}_k^j \right\|^2 w_{ij}^b = \\ \frac{1}{2} \sum_{i,j=1}^c \left\| \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{A}^T \mathbf{x}_k^i - \frac{1}{n_j} \sum_{k=1}^{n_j} \mathbf{A}^T \mathbf{x}_k^j \right\|^2 w_{ij}^b = \\ \frac{1}{2} \sum_{i,j=1}^c \|\mathbf{A}^T \mathbf{f}_i - \mathbf{A}^T \mathbf{f}_j\|^2 w_{ij}^b = \\ \sum_{i,j=1}^c \mathbf{A}^T \mathbf{f}_i \mathbf{D}_{ij}^b \mathbf{f}_j^T \mathbf{A} - \sum_{i,j=1}^c \mathbf{A}^T \mathbf{f}_i w_{ij}^b \mathbf{f}_j^T \mathbf{A} = \\ \text{tr}(\mathbf{A}^T \mathbf{F} \mathbf{L}^b \mathbf{F}^T \mathbf{A}) \end{aligned} \quad (13)$$

式中: $\mathbf{L}^b = \mathbf{D}^b - \mathbf{W}^b$; $\mathbf{D}^b = \sum_j w_{ij}^b$; $\mathbf{F} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_c]$; $\mathbf{f}_i = \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{x}_k^i$; $\text{tr}(\mathbf{A}^T \mathbf{F} \mathbf{L}^b \mathbf{F}^T \mathbf{A})$ 是类间离散度。

3.3 DSLPP 算法

联合考虑类内紧凑度和类间离散度,本文先给出 DSLPP 算法的目标函数如下

$$\max_A \frac{\text{tr}(\mathbf{A}^T \mathbf{F} \mathbf{L}^b \mathbf{F}^T \mathbf{A})}{\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{A})} \quad (14)$$

一般情况下,不能直接得到这个迹比函数的最优解^[14]。本文进一步化简式(14),得到 DSLPP 算法的目标函数

$$\max_A \text{tr}[(\mathbf{A}^T \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{A})^{-1} (\mathbf{A}^T \mathbf{F} \mathbf{L}^b \mathbf{F}^T \mathbf{A})] \quad (15)$$

在分类问题中,当样本维数高、可获得的样本数少的情况下,矩阵 $\mathbf{X} \mathbf{L}^w \mathbf{X}^T$ 总是奇异的。为了避免矩阵 $\mathbf{X} \mathbf{L}^w \mathbf{X}^T$ 的奇异性,本文首先用 PCA 对训练样本进行降维。

DSLPP 算法的主要步骤可归纳如下。

(1)对原始样本 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 用 PCA 方法投影到一个低维子空间,记 $\mathbf{A}_{\text{PCA}}$ 为 PCA 在低维空间的投影矩阵,则 $\mathbf{A}_{\text{PCA}}^T \mathbf{X}$ 为 PCA 降维后的样本。为书写方便,仍用 $\mathbf{X}$ 表示 PCA 降维后的样本。

(2)用式(12)计算类间离散度矩阵 $\mathbf{W}^b$ 。

(3)用式(5)计算类内紧凑度矩阵 $\mathbf{W}^w$ 。

(4)解特征方程 $\mathbf{F} \mathbf{L}^b \mathbf{F}^T \mathbf{A} = \lambda \mathbf{X} \mathbf{L}^w \mathbf{X}^T \mathbf{A}$,则最优投

影向量为 $(\mathbf{X} \mathbf{L}^w \mathbf{X}^T)^{-1} (\mathbf{F} \mathbf{L}^b \mathbf{F}^T)$ 的 d 个最大特征值所对应的特征向量为 $(\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d)$,最优投影矩阵 $\mathbf{A}^* = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$ 。

(5)DSLPP 的最优投影向量 $\mathbf{A}_{\text{DSLPP}} = \mathbf{A}_{\text{PCA}} \mathbf{A}^*$ 。

3.4 时间复杂度分析

DSLPP 算法主要是针对 DSNPE 算法时间复杂度高而提出的新算法。下面是关于这两种算法时间复杂度的比较。

DSLPP 算法的计算时间主要包括稀疏表示的求解和广义特征值分解两部分。采用标准线性规划来求解式(4)的复杂度为 $4km^2/3 + kmn + O(kn)$,其中 n 为训练样本的个数, m 为维数, k 为标准线性规划迭代的次数^[15]。与本文算法最相近的 DSNPE 算法的计算时间为 $\sum_{i=1}^c n_i (4km^2/3 + kmn_i + O(kn_i)) + \sum_{i=1}^c (n - n_i + 1) (4km^2/3) + km(n - n_i + 1) + O(k(n - n_i + 1))$,而本文 DSLPP 算法的计算时间为 $\sum_{i=1}^c n_i (4km^2/3 + kmn_i + O(kn_i)) + c(4km^2/3 + kmc + O(kc))$,很明显,从第 2 项看,本文算法的计算时间远远少于 DSNPE。在计算广义特征值分解时 2 种方法的计算复杂度均为 $O(m^3)$ 。

4 实验结果及分析

为了验证算法的有效性,将本文提出的 DSLPP 算法与其他算法(如 LDA、LPP、DLPP、NPE、SPP、DSNPE)在 Yale 人脸库^[16]、UMIST 人脸库^[17] 和 AR 人脸库^[18] 上进行实验,并将实验结果进行了比较。这 3 个人脸库在人脸面部细节、姿态、光照、以及图片背景等方面均存在很大的差异,因此能够很好地检验算法的鲁棒性。为公平比较,将所有相比较的算法首先用 PCA 方法预处理,对 Yale 和 UMIST 人脸库保持 98% 的图像能量,即保持原数据一定信息的前提下降维;对 AR 人脸库设置最大约简维数为 300。LDA 算法最多投影出 $c-1$ 特征, c 为类别个数。对于 LPP、DLPP、NPE 算法,以步长为 1 从 $K=[1,10]$ 区间中搜索最优近邻个数 K ,热核参数 σ 为训练样本范数的均值。所有实验都采用最近邻分类器进行分类。实验环境:计算机 CPU 为 Intel(R) Xeon(R) W3505 @ 2.53 GHz,内存 3.98 GB,操作系统 Windows XP Professional,操作软件为 MATLAB 7.10(R2012a)。

Yale 人脸库共有 165 张人脸图片,每人 11 张。

所有图片被裁剪为 64×64 像素大小。Yale 数据库用来测试有光照、表情变化及有饰物(眼镜)条件下算法的识别性能。实验过程中,对每个人的图片分别随机选样本个数 $l=4,5,6$ 幅图像进行训练,其余样本用于识别。每个样本数 l 下重复进行 20 组实验,最后取 20 次实验结果的均值作为最终结果进行分析。表 1 给出了分别采用 LDA、LPP、DLPP、NPE、SPP、DSNPE 和 DSLPP 算法在 Yale 人脸数据库上的平均识别率。图 1 给出了 7 种算法在 Yale 人脸库上的识别结果。

UMIST 人脸库由 20 个不同的人在不同姿势下拍摄的 575 幅图片组成,每幅图像的大小为 112×92 像素。每一组图片都有从侧面到正面的不同姿态,这 20 个图像涵盖了不同种族、性别、面貌特征的情况。实验过程中,对每个人的图像分别随机选取样本数 $l=5,7,9$ 幅图像进行训练,其余样本用于识别。每个 l 重复进行 20 组实验,最后取 20 次实验结果的均值作为最终结果进行分析。表 2 给出了 LDA、LPP、DLPP、NPE、SPP、DSNPE 和 DSLPP 算法在 UMIST 人脸数据库上的最高平均识别率。图 2 给出了 7 种算法在 UMIST 人脸库上的识别结果。

AR 彩色人脸库包含超过 4 000 幅的图像, 共
表 1 7 种算法在 Yale 数据的最高平均识别率

算法	最高平均识别率		
	$l=4$	$l=5$	$l=6$
LDA	0.730 0	0.767 3	0.804 0
LPP	0.769 0	0.768 9	0.812 7
DLPP	0.789 5	0.821 7	0.825 3
NPE	0.772 9	0.782 8	0.807 3
SPP	0.776 7	0.799 4	0.807 3
DSNPE	0.733 8	0.815 6	0.832 7
DSLPP	0.814 8	0.833 3	0.853 3

表 2 7 种算法在 UMIST 数据的最高平均识别率

算法	最高平均识别率		
	$l=5$	$l=7$	$l=9$
LDA	0.908 8	0.934 2	0.959 2
LPP	0.814 3	0.869 5	0.924 6
DLPP	0.890 6	0.936 3	0.955 4
NPE	0.816 2	0.870 3	0.919 3
SPP	0.821 1	0.895 4	0.924 4
DSNPE	0.852 4	0.914 7	0.954 7
DSLPP	0.927 1	0.965 3	0.979 4






图 1 样本数分别为 4、5、6 时 7 种算法在 Yale 人脸库上的识别结果

126 人,其中男性 70 名,女性 56 名。AR 人脸库主要包含表情、光照和遮挡等变化,图像分辨率为 165×120 像素。同文献[19]一样,我们选取一个包含 50 名男性和 50 名女性的子库(仅有光照和表情变化),每人选取 14 张图像,其中 7 张作为训练样本,剩余 7 张作为测试样本。为了简化识别过程,将图像裁剪为 60×43 像素。图 3 给出了对 AR 人脸训练的识别结果。表 3 给出了 LDA、LPP、DLPP、NPE、SPP、DSNPE 和 DSLPP 算法在 AR 人脸库上的最高识别率和对应的维数。

从实验结果可以看出,DSLPP 算法在 Yale、UMIST 库上的平均识别率及 AR 库上的最高识别




图 2 样本数分别为 5、7、9 时 7 种算法在 UMIST 人脸库上的识别结果




图 3 7 种算法在 AR 人脸库上的识别结果

表 3 7 种算法在 AR 人脸库上的最高识别率和对应的维数

算法	最高识别率	维数
LDA	0.810 0	99
LPP	0.575 7	99
DLPP	0.755 7	99
NPE	0.677 1	79
SPP	0.620 0	259
DSNPE	0.711 4	239
DSLPP	0.837 1	99

率分别达 83.38%、95.72%、83.71%，较其他传统方法的识别率有明显提高。LDA、LPP、NPE、SPP 算法的识别率相对较低一些，这是因为这 3 种算法均没有考虑类别信息。虽然 DLPP 和 DSNPE 算法均考虑了类别信息，并且都考虑了局部和全局结构信息，但 DSNPE 算法的识别率高于 DLPP 算法的，这可能主要因为 DSNPE 算法是基于稀疏表示法自适应地确定类内类间相似度。与 DSNPE 算法相比，DSLPP 算法获得了更好的识别率，这主要是因为 DSLPP 算法中所采用的新的类间离散度最大限度地扩大了不同类别中各个样本点之间的差异，从而获得了更好的类间判别力。

在上述所比较的算法中仅有 SPP、DSNPE、DSLPP 算法采用稀疏表示的方法自适应确定权重矩阵。为了进一步验证本文算法的有效性，对这 3 种算法在 UMIST 人脸库上进行了计算时间的比较，实验结果如表 4 所示。因为 SPP 算法采用稀疏表示的方法自适应设置了整个样本集的权重矩阵，而 DSNPE 算法采用稀疏表示不仅设置了类内权重矩阵，而且设置了类间权重矩阵，因此 DSNPE 比 SPP 算法耗时。本文所提 DSLPP 算法也采用稀疏表示方法自适应确定了类内权重矩阵和类间权重矩阵，但正是 DSLPP 算法中采用了合理的稀疏表示字典设计，从而大大降低了算法的计算时间。从表 4 可以看出，与 SPP 和 DSNPE 算法相比较，DSLPP 算法的运行时间明显少得多。

表 4 算法运行时间的比较

算法	运行时间/s		
	$l=5$	$l=7$	$l=9$
SPP	32.9	53.5	94.6
DSNPE	52.4	85.1	135.3
DSLPP	9.67	15.7	23.4

5 结 论

本文提出了一种新的维数约简的算法,即鉴别稀疏局部保持投影的人脸识别算法(DSLPP)。一方面,DSLPP算法简化了稀疏表示字典的构造,降低了计算时间的复杂度;另一方面,DSLPP算法保持了不同类平均向量的稀疏重构关系,考虑了全局判别结构,扩大了不同类数据之间的距离,算法具有较好判别力。在Yale、UMIST和AR人脸库上的实验表明,DSLPP算法的分类识别结果优于其他方法。今后我们会结合基于概率和Bayesian理论的人脸识别方法对本文方法作进一步的改进。

参考文献:

- [1] JOLLIFFE I T. Principal component analysis [M]. Berlin, Germany: Springer-Verlag, 1986: 111-137.
- [2] BELHUMEUR P N, HESPANHA J P, KRIENG-MAN D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 1997, 19(7): 711-720.
- [3] TENENBAUM J B, Silva V D, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290: 2319-2323.
- [4] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396.
- [5] HE X, CAI D, YAN S, et al. Neighborhood preserving embedding [C] // Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2005: 1208-1213.
- [6] HE X, YAN S, HU Y, et al. Learning a locality preserving subspace for visual recognition [C] // Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2003: 385-392.
- [7] YU W, TENG X, LIU C. Face recognition using discriminant locality preserving projections [J]. Image and Vision Computing, 2006, 24(3): 239-248.
- [8] WRIGHT J, YANG A Y, GANESH A, et al. Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [9] 陈思宝, 许立仙, 罗彬. 基于多重核的稀疏表示分类 [J]. 电子学报, 2014, 42(9): 1807-1811.
- CHEN Sibao, XU Lixian, LUO Bin. Multiple kernel sparse representation based classification [J]. Acta Electronica Sinica, 2014, 42(9): 1807-1811.
- [10] WRIGHT J, MA Y, MAIRAL J, et al. Sparse representation for computer vision and pattern recognition [J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.
- [11] 杜春, 孙即祥, 周石琳, 等. 基于稀疏表示和非参数判别分析的降维算法 [J]. 国防科技大学学报, 2013, 35(2): 143-147.
- DU Chun, SUN Jixiang, ZHOU Shilin, et al. Dimensionality reduction based on sparse representation and nonparametric discriminant analysis [J]. Journal of National University of Defense Technology, 2013, 35(2): 143-147.
- [12] QIAO L S, CHEN S C, TAN X Y. Sparsity preserving projections with applications to face recognition [J]. Pattern Recognition, 2010, 43(1): 331-341.
- [13] LU G F, JIN Z, ZOU J. Face recognition using discriminant sparsity neighborhood preserving embedding [J]. Knowledge-Based Systems, 2012, 31(7): 119-127.
- [14] JIA Y Q, NIE F P, ZHANG C S. Trace ratio problem revisited [J]. IEEE Transactions on Neural Networks, 2009, 20(4): 729-735.
- [15] DONOHO D L, TSAIGs Y. Fast solution of L1-norm minimization problems when the solution may be sparse [J]. IEEE Transactions on Information Theory, 2008, 54(11): 4789-4812.
- [16] HE Xiaofei. See [EB/OL]. (2012-02-27) [2015-10-29]. <http://www.cad.zju.edu.cn/home/dengcai/Data/FaceData.html>.
- [17] GRAHAM D B, ALLINSON N M. Characterizing virtual eigensignatures for general purpose face recognition [M]. Berlin, Germany: Springer-Verlag, 1998: 446-456.
- [18] MARTINEZ A M, BENAVENTE R. The AR face database, compute vision center technical report # 24 [R]. Birmingham, AL, USA: University of Alabama at Birmingham, 1998.
- [19] GUI Jie, SUN Zhenan, JIA Wei, et al. Discriminant sparse neighborhood preserving embedding for face recognition [J]. Pattern Recognition, 2012, 45(8): 2884-2893.

(编辑 刘杨)