

文章编号: 0258-2724(2013)06-1097-07 DOI: 10.3969/j.issn.0258-2724.2013.06.020

# 一种基于核局部保留投影的人脸识别方法

齐永锋<sup>1</sup>, 火元莲<sup>2</sup>

(1. 西北师范大学计算机科学与工程学院, 甘肃 兰州 730070; 2. 西北师范大学物理与电子工程学院, 甘肃 兰州 730070)

**摘要:** 为了有效提取人脸的非线性结构信息, 提出一种新的基于最大散度差的核判别局部保留投影方法. 首先通过核函数将样本数据映射到高维特征空间, 计算特征空间中样本的散度矩阵, 其次将样本原始空间中的近邻图嵌入到散度矩阵, 最后采用最大散度差准则进行特征提取. 在 PIE 与 Yale 人脸数据库上的实验结果表明, 提出的人脸识别方法最高识别率可达到 99%.

**关键词:** 人脸识别; 非线性分析; 最大散度差; 局部保留投影

**中图分类号:** TP391 **文献标志码:** A

## A Face Recognition Method Based on Kernel Locality Preserving Projection

QI Yongfeng<sup>1</sup>, HUO Yuanlian<sup>2</sup>

(1. College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China; 2. College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou 730070, China)

**Abstract:** To effectively extract non-linear structure information of face images, a novel method based on maximum scatter difference rule was proposed in this paper. Firstly, the kernel function was used to map original sample data into high dimensional feature space and the scatter matrices were obtained. Secondly, the nearest graphs of original sample data were embedded into scatter matrices; then the maximum scatter difference was used to extract the feature of samples. Experimental results on Pie and Yale face databases demonstrate that the proposed face recognition method is efficient and its top recognition rate can reach 99%.

**Key words:** face recognition; nonlinear analysis; maximum scatter difference; locality preserving projection

由于在金融、司法和人机界面等邻域的广泛应用前景, 人脸识别一直是模式识别领域的研究热点<sup>[1-3]</sup>. 近年来, 研究者提出了许多人脸识别方法, 总体上可将其归纳为 2 维人脸识别方法与 3 维人脸识别方法<sup>[4]</sup>两类. 在 2 维人脸识别方法中, 光照和姿态变化是影响识别精度的重要因素, 为了克服这些不足, 许多研究者进行 3 维人脸识别方法的研究<sup>[5-7]</sup>, 以期得到比 2 维方法更高的识别精度. 在人脸识别任务中, 特征提取方法是至关重要的, 在众

多特征提取方法中, 基于子空间的方法是最为成功并被高度关注的方法之一. 基于子空间的方法通常利用降维技术将高维的人脸向量投影到低维的特征空间, 然后在低维特征空间进行分类. 其中主成分分析(principal component analysis, PCA)与线性判别式分析(linear discriminant analysis, LDA)是最常见的两种降维方法. PCA 是一种在最小均方误差意义下的最佳重构方法, 由于其忽略了样本的类别信息, 因此不是最佳的识别方法. LDA 充分利

收稿日期: 2012-05-16

基金项目: 国家自然科学基金资助项目(61262056, 51175443)

作者简介: 齐永锋(1971-), 男, 副教授, 博士, 研究方向为模式识别与图像处理, E-mail: qiyf@nwnu.edu.cn

用了样本的类别信息,但在人脸识别任务中,由于数据维数远远高于训练样本数,因此存在小样本问题.最大散度差准则(maximum scatter difference, MSD)<sup>[8]</sup>是最近提出的一种线性降维方法,其目的是通过最大化样本散度差来发现最佳投影轴. MSD是LDA的一种变形,将类间散度与类内散度的商变形为差,从而避免了LDA由于类内散度的奇异性导致的小样本问题.为了改进MSD提取特征的鉴别性,研究者对MSD准则进行了一些改进. Li等提出了中值最大散度差(median maximum scatter difference, MMSD)人脸识别方法<sup>[9]</sup>,该方法用样本中值替换了MSD中样本的均值,是MSD的一种变形; Wang等也通过图像投影技术将MSD扩展到二维,提出了二维最大散度差准则<sup>[10]</sup>.

由于人脸的非刚性特征以及光照、饰物等因素的影响,人脸图像往往存在于非线性子空间上. PCA、LDA及MSD是线性的特征提取方法,不能有效提取人脸的非线性特征,为了提取人脸的非线性特征,一些基于核函数的方法被提出. Kim等提出了基于核主成分分析(kernel principal component analysis, KPCA)的人脸识别方法<sup>[11]</sup>, Lu等提出了核直接判别式分析(kernel direct discriminant analysis, KDDA)人脸识别方法<sup>[12]</sup>. 这些基于核函数的方法首先通过非线性函数将低维的线性空间映射到高维的特征空间,然后进行数据降维. 最近, Wang等提出了核最大散度差(kernel maximum scatter difference, KMSD)人脸识别方法<sup>[13]</sup>,该方法本质上是一种KPCA+MSD的两阶段特征提取方法,首先通过KPCA对样本进行特征提取,然后再用MSD对KPCA提取的特征进行二次特征提取. 基于核函数的方法能够较好地提取数据的全局结构特征,但往往忽视了数据的局部结构特征.

流形学习算法是另一种揭示样本非线性结构的方法. 与基于核函数的方法相比较,流形学习算法能够有效保留数据的局部结构信息. 最近的研究表明,人脸的局部结构信息在人脸识别中具有重要的作用<sup>[14-16]</sup>. 拉普拉斯特征映射(Laplacian Eigenmap)<sup>[17]</sup>能够有效提取数据局部结构信息,但由于没有明确的投影矩阵, Laplacian Eigenmap很难直接提取新样本的特征. LPP<sup>[18]</sup>是Laplacian Eigenmap方法的一种线性近似解,可有效解决Laplacian Eigenmap存在的问题. LPP是一种线性非监督方法,没有利用样本的类别信息. 为了充分利用样本的类别信息, Yu等结合Fisher准则提出

了判别局部保留投影(DLPP)方法<sup>[19]</sup>,并将其扩展为二维判别局部保留投影(2DLPP)方法<sup>[20]</sup>. 最近,研究者将样本最近邻图嵌入了一些判别准则,提出了不同形式的局部鉴别保留投影方法<sup>[21-23]</sup>.

流形学习算法通过邻接图嵌入得到的低维子空间,可很好地描述样本的局部结构,但对样本的全局结构信息缺乏描述. 不论人脸的全局结构信息还是局部结构信息,在人脸识别中都具有重要作用. 为了同时提取人脸的局部信息与全局信息,本文提出基于最大散度差的核判别局部保留投影方法. 本文主要创新点如下:首先通过核函数将样本映射到高维的非线性空间,然后将表示原始空间样本间局部结构的最近邻图嵌入到散度矩阵,利用最大散度差准则提取样本判别特征. 这样,本文提出的方法具有以下特点:(1)非线性;(2)是监督学习算法;(3)充分利用了样本的局部结构信息和全局结构信息.

## 1 最大散度差(MSD)准则

MSD准则的目的是找到一个转换矩阵 $W$ ,通过线性变换 $Y = WX$ 将高维空间 $\mathbf{R}^n$ 中的数据集 $X = (x_1, x_2, \dots, x_M)$ 投影到低维空间 $\mathbf{R}^d (d \ll n)$ ,使得样本类间散度与类内散度的差最大化. 假设在训练集中有 $M$ 个已知类别的样本 $x_i \in \mathbf{R}^n (i = 1, \dots, M)$ ,分属于 $C$ 类,每类有 $n$ 个样本,即 $Cn = M$ . MSD的目标函数为

$$J(W_{\text{MSD}}) = \max W^T (S_b - S_w) W, \quad (1)$$

式中: $S_b$ 与 $S_w$ 分别表示样本的类间散度矩阵与类内散度矩阵,则:

$$S_b = \sum_{i=1}^C (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T = \frac{1}{2C} \sum_{i=1}^C \sum_{j=1}^C (\bar{x}_i - \bar{x}_j)(\bar{x}_i - \bar{x}_j)^T, \quad (2)$$

$$S_w = \sum_{i=1}^C \sum_{j=1}^n (\bar{x}_i^j - \bar{x}_i)(\bar{x}_i^j - \bar{x}_i)^T = \frac{1}{2n} \sum_{i=1}^C \sum_{x_j \in I_i} (x_i - x_j)(x_i - x_j)^T, \quad (3)$$

式中: $x_{ij}$ 表示第 $i$ 类的第 $j$ 个样本; $\bar{x}_i$ 表示第 $i$ 类样本的均值; $\bar{x}$ 表示所有样本的均值; $I_i$ 表示第 $i$ 类样本.

显然,转换矩阵 $W = (w_1, w_2, \dots, w_d)$ 由 $S_b - S_w$ 的前 $d$ 个最大特征值 $\lambda_1, \lambda_2, \dots, \lambda_d$ 对应的特征向量组成.

## 2 基于最大散度差的核判别局部保留投影方法

### 2.1 基本原理

首先用一个非线性映射函数将原始样本空间的向量映射到高维的特征空间  $F$ :

$$\begin{aligned} \Phi: \mathbf{R}^n \rightarrow F, \\ x \mapsto \Phi(x), \end{aligned} \quad (4)$$

原始空间中的数据集  $x_1, x_2, \dots, x_M$  经函数  $\Phi$  被映射为特征空间的数据集  $\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)$ . 为了表示方便, 下文均用  $\Phi_1, \Phi_2, \dots, \Phi_M$  代表  $\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)$ . 由于特征空间维

$$H_{ij} = \begin{cases} \exp(-\|x_{ij} - x_{il}\|^2), & \text{如果 } x_{il} \text{ 与 } x_{ij} \text{ 属于 } i \text{ 类;} \\ 0, & \text{否则;} \end{cases} \quad (7)$$

$$Q_{ij} = \begin{cases} \exp(-(\|\bar{x}_i - \bar{x}_j\|^2)/t), & \text{如果 } \bar{x}_j \text{ 是 } \bar{x}_i \text{ 的 } k \text{ 最近邻, 同时 } \bar{x}_i \text{ 是 } \bar{x}_j \text{ 的 } k \text{ 最近邻;} \\ 0, & \text{否则.} \end{cases} \quad (8)$$

通过嵌入  $Q$ , 可降低类间散度矩阵过分强调较大间距的类而导致相邻类的重叠. 嵌入  $Q$  后, 类间散度矩阵可写为

$$\begin{aligned} \tilde{S}_{\Phi_b} &= \frac{n^2}{2C} \sum_{i=1}^C \sum_{j=1}^C (\bar{\Phi}_i - \bar{\Phi}_j) (\bar{\Phi}_i - \bar{\Phi}_j)^T Q_{ij} = \\ &= \frac{n^2}{C} \left[ \sum_{i=1}^C D_{ii} \bar{\Phi}_i (\bar{\Phi}_i)^T - \sum_{i=1}^C \sum_{j=1}^C Q_{ij} \bar{\Phi}_i (\bar{\Phi}_j)^T \right] = \\ &= \frac{n^2}{C} (\bar{\Phi} D \bar{\Phi}^T - \bar{\Phi} Q \bar{\Phi}^T) = \frac{n^2}{C} \bar{\Phi} L \bar{\Phi}^T = \\ &= \bar{\Phi} E L E^T \bar{\Phi}^T, \end{aligned} \quad (9)$$

其中:  $\bar{\Phi} = (\bar{\Phi}_1, \bar{\Phi}_2, \dots, \bar{\Phi}_C)$ ;  $D$  为对角矩阵, 其元素为  $D_{ii} = \sum_{j=1}^n Q_{ij}$ ;  $L = D - Q$  为拉普拉斯矩阵;  $\Phi = (\Phi_{11}, \Phi_{12}, \dots, \Phi_{1n}, \dots, \Phi_{C1}, \Phi_{C2}, \dots, \Phi_{Cn})$ ;  $E$  为分块对角矩阵, 即

$$E = \frac{1}{\sqrt{C}} \begin{bmatrix} e & 0 & \dots & 0 \\ 0 & e & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & e \end{bmatrix},$$

其中:  $e = (1, 1, \dots, 1)^T$  为  $n$  维向量.

嵌入  $H$  后, 类内散度矩阵可写为

$$\begin{aligned} \tilde{S}_{\Phi_w} &= \frac{1}{2n} \sum_{i=1}^C \sum_{\Phi_j, \Phi_l \in i} (\Phi_{ij} - \Phi_{il}) (\Phi_{ij} - \Phi_{il})^T H_{ij} = \\ &= \frac{1}{n} \sum_{i=1}^C \left[ \sum_{j=1}^n H_{ij} \Phi_j (\Phi_j)^T - \sum_{j=1}^n \sum_{l=1}^n H_{ij} \Phi_j (\Phi_l)^T \right] = \\ &= \frac{1}{n} \sum_{i=1}^C \Phi_i (F_i - H_i) (\Phi_i)^T = \end{aligned}$$

数远高于原始空间, 在原始空间中不能线性分离的数据在特征空间可很好地被线性分离. 特征空间中类间散度矩阵与类内散度矩阵分别为<sup>[12]</sup>

$$S_{\Phi_b} = \frac{n}{2C} \sum_{i=1}^C \sum_{j=1}^C n (\bar{\Phi}_i - \bar{\Phi}_j) (\bar{\Phi}_i - \bar{\Phi}_j)^T, \quad (5)$$

$$S_{\Phi_w} = \frac{1}{2n} \sum_{i=1}^C \sum_{\Phi_j, \Phi_l \in i} (\Phi_{ij} - \Phi_{il}) (\Phi_{ij} - \Phi_{il})^T. \quad (6)$$

为了在特征空间保持数据在原始空间的相似性, 将表示原始空间数据类间相似度的矩阵  $H$  与类平均向量之间相似度的矩阵  $Q$  分别嵌入在  $S_{\Phi_b}$  与  $S_{\Phi_w}$  中.

在本文  $H$  与  $Q$  被定义为

$$\frac{1}{n} \Phi (F - H) \Phi^T = \frac{1}{n} \Phi P \Phi^T, \quad (10)$$

式中:

$$\Phi = (\Phi_{11}, \Phi_{12}, \dots, \Phi_{1n}, \dots, \Phi_{C1}, \Phi_{C2}, \dots, \Phi_{Cn});$$

$$F_i \text{ 为对角矩阵, 其元素为 } F_{ij} = \sum_{j=1}^n H_{ij};$$

矩阵  $F$  和  $H$  分别为

$$F = \begin{bmatrix} F_1 & 0 & \dots & 0 \\ 0 & F_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & F_C \end{bmatrix},$$

$$H = \begin{bmatrix} H_1 & 0 & \dots & 0 \\ 0 & H_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & H_C \end{bmatrix}.$$

目标函数可写为

$$J(W_{\Phi_{MSD}}) = \max\{\text{tr}[W_{\Phi}^T (\tilde{S}_{\Phi_b} - \tilde{S}_{\Phi_w}) W_{\Phi}]\}. \quad (11)$$

在特征空间中, 转换矩阵  $W_{\Phi}$  的列向量  $w_{\Phi_i}$  可表示为  $\Phi_1, \Phi_2, \dots, \Phi_M$  的线性组合:

$$w_{\Phi_i} = \sum_{j=1}^M z_{ij} \Phi_j = R z_i, \quad i = 1, 2, \dots, d, \quad (12)$$

式中:  $R = (\Phi_1, \Phi_2, \dots, \Phi_M)$ ;  $z_i = (z_{i1}, z_{i2}, \dots, z_{iM})^T$ .

转换矩阵  $W_{\Phi}$  可表示为

$$W_{\Phi} = RZ. \quad (13)$$

因此,目标函数(11)可表示为

$$\begin{aligned}
 J(Z) &= \max\{\text{tr}[W_\phi^T(\bar{S}_{\phi_b} - \bar{S}_{\phi_w})W_\phi]\} = \\
 &= \max\{\text{tr}[Z^T R^T(\bar{S}_{\phi_b} - \bar{S}_{\phi_w})RZ]\} = \\
 &= \max\{\text{tr}[Z^T R^T R(ELE - P)R^T RZ]\} = \\
 &= \max\{\text{tr}[Z^T K(ELE - P)KZ]\}, \quad (14)
 \end{aligned}$$

式中:  $K = R^T R$  其元素为

$$K_{ij} = \Phi^T(x_i)\Phi(x_j) = \Phi(x_i) \cdot \Phi(x_j) = K(x_i, x_j).$$

为了使得  $J(Z)$  最大,  $Z = (z_1, z_2, \dots, z_d)$  由  $K(ELE - P)K$  的前  $d$  个最大特征值对应的特征向量组成.

### 2.2 特征提取与分类

给定一个人脸样本  $x \in R^N$  与它的核映射向量  $\Phi(x)$  将其投影到转换矩阵  $W_\phi$  可得到其判别特征向量为

$$\begin{aligned}
 y &= W_\phi^T \Phi(x) = Z^T R^T \Phi(x) = \\
 &= Z^T (\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M))^T \Phi(x) = \\
 &= Z^T [K(x_1, x), K(x_2, x), \dots, K(x_M, x)]. \quad (15)
 \end{aligned}$$

同样地,可得到训练样本  $x_i (i=1, 2, \dots, M)$  的特征向量  $y_i$ . 利用欧式距离最近邻分类器判别样本  $x$  的类别归属. 特征向量  $y$  与  $y_i$  间的欧式距离为

$$d(y, y_i) = \sum_{k=1}^d \|y_k - y_{ki}\|_2. \quad (16)$$

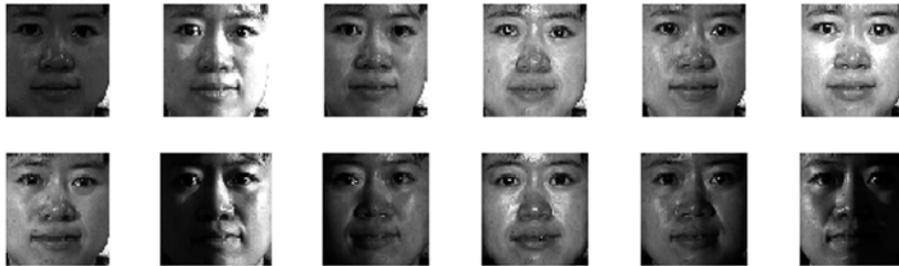


图1 在 PIE 数据库中一个人的部分脸图像  
Fig.1 Face images from one person on PIE database

每人随机选择 10、20 个人脸图像构建 2 个训练样本集,其余图像作为测试样本.为了得到稳定的识别性能,每个训练集与对应的测试集重复选择 10 次.图 2(a)与图 2(b)分别显示了 6 种算法在 10 个训练样本与 20 个训练样本下的平均识别率随特征维数的变化曲线.从图 2 中能够看到,本文算法、MMSD、MSD 和 KDDA 算法性能远好于 KPCA 和 DLPP 算法.且随着训练样本数的增加(20 个样本时),本文算法的这种性能优势更明显.

由于光照的影响,同一个人脸图像间的差异往往大于不同人脸图像间的差异.本文算法是基于判别准则的,且嵌入了同类样本的近邻图,因此强化

### 3 实验结果

在两个数据库 PIE([http://www.ri.cmu.edu/projects/project\\_418.html](http://www.ri.cmu.edu/projects/project_418.html))和 Yale(<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>)对提出的算法进行性能测试,并和 DLPP、MMSD、MSD、KPCA、KDDA 进行比较. PIE 数据库用来评估算法在光照变化条件下的识别性能; Yale 数据库用来评估算法在人脸样本有光照、表情和饰物(有无眼镜)情况下的识别性能. KDLPP、KPCA 与 KDDA 均采用多项式核函数:

$$K(x, y) = (x \cdot y + 1)^d, \quad (17)$$

其中  $d$  为常数,本文实验中  $d$  为 0.5. 所有算法都采用 Matlab 7.0 编程,在配置为 2.7 GHz CPU,内存为 512 MB 的微机上运行.

#### 3.1 在 PIE 数据库上的实验结果

PIE 数据库包含有 68 个不同个人的 41 368 张图片.在本实验中,每人选择 45 张不同光照的图像(无表情变化)进行算法性能测试,每张图像手工裁剪并缩放为  $64 \times 64$  像素大小,一个人的部分脸图像如图 1 所示.本实验用于评估在光照变化条件下算法的识别性能.

了同类样本间的聚类性与不同类样本间的分散性.在光照条件变化较大时,人脸图像往往呈非线性分布.本文算法是非线性的,因此能更好地提取人脸的非线性特征信息.

#### 3.2 在 Yale 数据库上的实验结果

Yale 数据库包含有 15 个不同个人的 165 张人脸图像,其中每人有 11 张包括光照变化、表情变化以及是否戴眼镜的照片.在实验中,通过手工将图片裁剪、缩放为  $64 \times 64$  像素大小,图 3 显示了一个人的样本图像. 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.

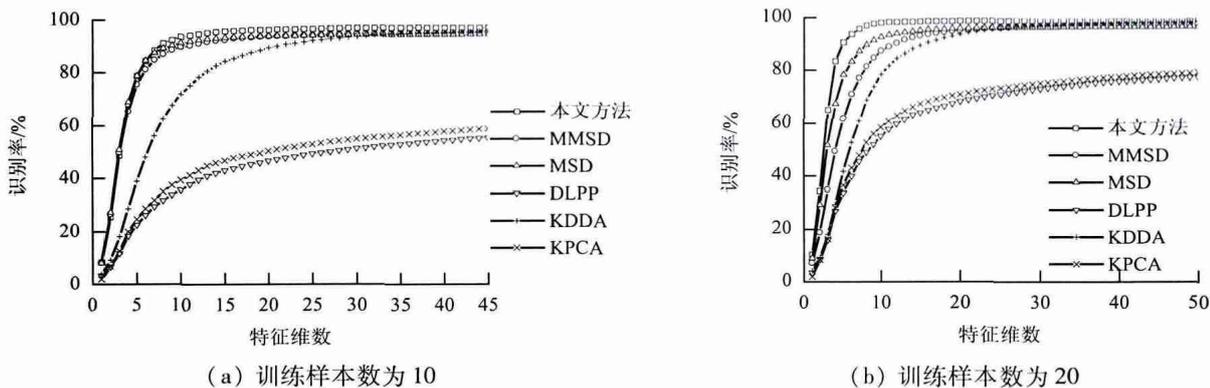


图 2 在 PIE 数据库上 6 种算法识别率随特征维数变化曲线  
Fig. 2 Recognition rate curves of six methods under various dimensions of feature

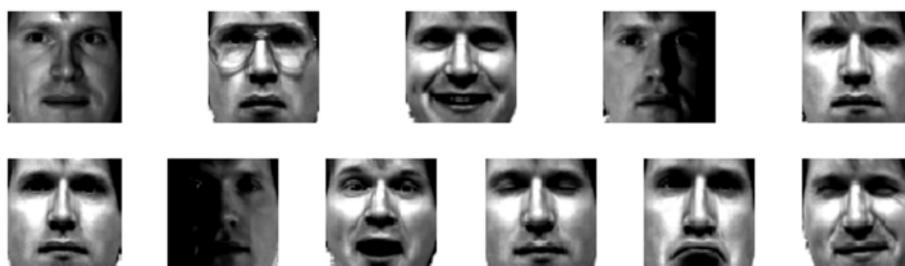


图 3 Yale 数据库上一个人的人脸图像  
Fig. 3 Face images from one person on Yale database

首先测试在不同特征维数下算法的最佳识别率与运算速度. 每人选择前 5 张图像作为训练样本, 其余图像作为测试样本. 表 1 给出了本文算法、MMSD、MSD、KPCA、KDDA 与 DLPP 六种算法的最优识别率、对应的特征维数和算法运行时间. 从表 1 能够发现, 本文算法最优识别率高于其余算法, 且速度较快.

表 1 在 Yale 数据库上最优识别率及运算速度比较  
Tab. 1 Comparison of the optimal recognition rates and running time on Yale database

方法	最佳识别率 / %	特征维数	运行时间 / s
KDDA	84.44	12	9.156 3
KPCA	84.44	28	2.484 1
MMSD	86.67	24	2.421 9
MSD	86.67	13	2.218 8
DLPP	85.56	35	3.203 1
本文方法	90.00	13	2.156 3

其次测试不同训练样本数下算法的识别性能. 每人随机选择  $p = 2, 3, \dots, 7$  张图像作为训练样本, 其余图像作为测试样本. 针对每个  $p$  的取值重复选择 10 次,  $\beta$  种算法的最佳平均识别率、标准差及对应特征维数(括号中的数据)如表 2 所示. 从表 2

可以发现, 当训练样本数较少(2 个和 3 个)时, MMSD 有较好的识别率, 但随着训练样本数的增加, 本文提出的算法识别率优于其余算法. 从表 2 也能够看到, MMSD 在不同训练样本数下, 其标准差较大, 说明训练样本集的选择对算法识别性能影响较大. 通过计算得到 KDDA、MMSD、DLPP、MSD、KPCA 和本文算法的平均标准差分别是 3.568 3、4.488 3、3.573 1、3.723 3、3.468 3 和 3.405 0, 说明训练样本集的选择对本文算法识别性能影响最小, 本文算法具有更好的鲁棒性. 在 Yale 数据库上的实验结果表明, 本文算法在人脸图像同时存在光照变化、表情变化和饰物(眼睛)时, 其识别性能优于 KDDA、MMSD、MSD、KPCA 和 DLPP.

### 3.3 结果分析

从两个数据库上的实验结果能够看到, 不论是在仅有光照变化、还是光照变化和表情变化都有的条件下, 本文提出的算法的识别性能均优于其余 5 种算法, 其主要原因如下: 与 KPCA 相比较, 本文算法是有监督的学习方法, 充分利用了样本类信息, 提高了算法的鉴别能力; 与 MMSD 和 MSD 相比较, 本文算法是非线性的, 能够更好地表示由光照、表情等变化引起的非线性特征; 与 KDDA 相比较,

表2 Yale数据库上不同训练样本数下的识别性能比较  
Tab. 2 Comparison of recognition rates under varying training sample numbers

训练样本数	KDDA	MMSD	DLPP	MSD	KPCA	本文算法
2	60.83 ± 4.39 (12)	64.07 ± 4.93 (14)	57.19 ± 3.21 (27)	64.07 ± 4.93 (14)	55.89 ± 3.17 (21)	63.48 ± 3.52 (12)
3	72.25 ± 3.73 (13)	75.92 ± 3.36 (15)	67.33 ± 3.73 (31)	73.17 ± 3.16 (14)	68.12 ± 2.81 (24)	74.28 ± 3.67 (13)
4	76.57 ± 4.86 (13)	80.00 ± 4.31 (15)	73.61 ± 4.05 (35)	80.01 ± 3.74 (15)	72.24 ± 2.91 (24)	81.29 ± 4.58 (14)
5	81.11 ± 2.16 (13)	83.22 ± 5.61 (15)	78.55 ± 4.34 (33)	83.67 ± 4.67 (17)	78.16 ± 4.13 (25)	84.56 ± 3.09 (13)
6	83.73 ± 2.58 (13)	85.2 ± 4.64 (14)	80.69 ± 3.69 (41)	85.71 ± 3.21 (16)	81.29 ± 3.62 (36)	87.07 ± 3.61 (14)
7	85.83 ± 3.69 (11)	88.67 ± 4.08 (15)	83.17 ± 2.17 (39)	89.17 ± 2.63 (15)	83.11 ± 4.17 (35)	90.89 ± 1.96 (14)

通过在最大散度差准则中嵌入同类样本的最近邻关系图,更进一步强化了特征空间中同类样本的聚类性与不同类样本间的分散性,其次,为了避免散度矩阵奇异性问题,KDDA删除了部分有用信息,降低了算法的性能;与DLPP相比较,本文方法既提取了局部结构信息,又提取了全局结构信息,因此能够更好地描述人脸特征。

## 4 结论

特征提取是人脸识别最重要的一个步骤,提取特征的鉴别力直接决定了人脸识别系统的性能。在表情、光照、饰物等因素的影响下,人脸本质特征不是简单的线性分布,而是复杂的非线性分布。本文采用核函数将人脸样本投影到高维非线性空间,可将低维空间中样本间的重叠有效地分离开;通过将同类样本间的最近邻关系图嵌入到最大散度差准则,可强化同类样本间的聚类性与不同类样本间的分散性,同时在高维空间保持了原始样本间的几何结构。在PIE和Yale人脸数据库上的实验结果表明,本文算法不论是在光照变化、表情变化、有无饰物的情况下都能很好地提取人脸特征,是一种有效的、鲁棒的特征提取方法。

### 参考文献:

[1] 张祖涛,张家树,和红杰. 基于脆弱数字水印的人脸图像的安全性[J]. 西南交通大学学报, 2007, 42(3): 340-344.  
ZHANG Zutao, ZHANG Jiashu, HE Hongjie. Safety of facial images based on fragile digital watermarking[J]. Journal of Southwest Jiaotong University, 2007, 42(3): 340-344.

[2] 张家树,陈辉,李德芳,等. 人脸表情自动识别技术研究进展[J]. 西南交通大学学报, 2005, 40(3): 285-292.  
ZHANG Jiashu, CHEN Hui, LI Defang, et al. Research advances in automatic facial expression recognition[J]. Journal of Southwest Jiaotong University, 2005, 40(3): 285-292.

[3] 齐永锋,火元莲. 一种结合2DLPP与2DPCA的人脸识别方法[J]. 西南交通大学学报, 2011, 46(6): 910-916.  
QI Yongfeng, HUO Yuanlian. Face Method Combining 2DLPP with 2DPCA[J]. Journal of Southwest Jiaotong University, 2011, 46(6): 910-916.

[4] ABATE A F, NAPPI M, RICCIO D, et al. 2D and 3D face recognition: A survey[J]. Pattern Letters, 2007, 28(14/15): 1885-1906.

[5] SMEETS D, KEUSTERMANS J, VANDERMEULEN D, et al. meshSIFT: Local surface features for 3D under expression variations and partial data[J]. Computer Vision and Image Understanding, 2013, 117(2): 158-169.

[6] LEI Yinjie, BENNAMOUN M, EL-SALLAM A A. An efficient 3D face recognition approach based on the fusion of novel local low-level features[J]. Pattern Recognition, 2013, 46(1): 24-37.

[7] ZHAO Zengshun, ZHANG Li, ZHAO Meng, et al. Gabor face recognition by multi-channel classifier fusion of supervised kernel manifold learning[J]. Neurocomputing, 2012, 97(15): 398-404.

[8] 宋枫溪,程科,杨静宇,等. 最大散度差和大间距线性投影与支持向量机[J]. 自动化学报, 2004, 30(6): 890-896.  
SONG Fengxi, CHENG Ke, YANG Jingyu, et al.

- Maximum scatter difference, large margin linear projection and support vector machines [J]. *Acta Automatica Sinica*, 2004, 30(11): 890-896.
- [9] LI Xiaodong, FEI Shumin, ZHANG Tao. Median MSD-based method for face recognition [J]. *Neurocomputing*, 2009, 72(16/17/18): 3930-3934.
- [10] WANG Jianguo, YANG Wankou, LIN Yusheng, et al. Two-directional maximum scatter difference discriminant analysis for face recognition [J]. *Neurocomputing*, 2008, 72(1/2/3): 352-358.
- [11] KIM K I, KEEECHUL J, KIM H J. Face recognition using kernel principal component analysis [J]. *IEEE Signal Processing Letters*, 2002, 9(2): 40-42.
- [12] LU Juwei, PLATANOTIS K N, VENETSANOPOULOS A N. Face recognition using kernel direct discriminant analysis algorithms [J]. *IEEE Transactions on Neural Networks*, 2003, 14(1): 117-126.
- [13] WANG Jianguo, LIN Yusheng, YANG Wankou, et al. Kernel maximum scatter difference based feature extraction and its application to face recognition [J]. *Pattern Recognition Letters*, 2008, 29(13): 1832-1835.
- [14] ZHANG Baochang, GAO Yongsheng, ZHAO Sanqiang, et al. Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor [J]. *IEEE Transactions on Image Processing*, 2010, 19(2): 533-544.
- [15] LU Guifu, LIN Zhong, JIN Zhong. Face recognition using discriminant locality preserving projections based on maximum margin criterion [J]. *Pattern Recognition*, 2010, 43(10): 3572-3579.
- [16] XU Yong, SONG Fengxi, FENG Ge, et al. A novel local preserving projection scheme for use with face recognition [J]. *Expert Systems with Applications*, 2010, 37(9): 7618-7621.
- [17] MIKHAIL B, PARTHA M. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6): 1373-1396.
- [18] HE Xiaofei, YAN Shuicheng, HU Yuxiao, et al. Face recognition using Laplacianfaces [J]. *IEEE Transactions Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328-340.
- [19] YU Weiwei, TENG Xiaolong, LIU Chongqing. Face recognition using discriminant locality preserving projections [J]. *Image and Vision Computing*, 2006, 24(3): 239-248.
- [20] YU Weiwei. Two-dimensional discriminant locality preserving projections for face recognition [J]. *Pattern Recognition Letters*, 2009, 30(15): 1378-1383.
- [21] QIAO Lishan, ZHANG Limei, CHEN Songcan. An empirical study of two typical locality preserving linear discriminant analysis methods [J]. *Neurocomputing*, 2010, 73(10/11/12): 1587-1594.
- [22] QIAO Lishan, CHEN Songcan, TAN Xiaoyang. Sparsity preserving discriminant analysis for single training image face recognition [J]. *Pattern Recognition Letters*, 2010, 31(5): 422-429.
- [23] 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 Weiguo, GU Xiaohua, et al. Complete discriminant locality preserving projections for face recognition [J]. *Journal of Software*. 2010, 21(6): 1277-1286.

(中文编辑:唐晴 英文编辑:周尧)