

# 融合全局与局部多样性特征的人脸表情识别

李雅倩<sup>1,2</sup> 李颖杰<sup>1</sup> 李海滨<sup>1,2\*</sup> 张 强<sup>1</sup> 张文明<sup>1,2</sup>

(<sup>1</sup>燕山大学工业计算机控制工程河北省重点实验室, 河北 秦皇岛 066004)  
(<sup>2</sup>国家冷轧板带装备及工艺工程技术研究中心, 河北 秦皇岛 066004)

**摘要** 通常主成分分析(PCA)只能保持数据的全局结构,邻域保持嵌入(NPE)算法只能保持邻域样本间的相似性,忽略了其差异性。针对上述问题,提出了一种融合全局与局部多样性的特征提取算法,并将其应用于人脸表情识别中。该算法利用 PCA 算法保持全局结构,并通过流形学习思想定义局部差异离散度和局部相似离散度,结合最大局部散度差准则,有效刻画出局部流形结构的多样性;将全局特征和局部多样性特征相结合,提取出低维流形特征用于表情分类。在 JAFFE 和 Cohn-Kanade 人脸表情数据库上的实验表明,该算法与 PCA、局部保持投影(LPP)、NPE 等算法相比,不仅有效地提高了识别率,而且在取得最高识别率时所需维数最低,证明了此算法在识别效果方面的优越性。

**关键词** 机器视觉;表情识别;流形学习;特征提取

**中图分类号** TP391.4 **文献标识码** A **doi**: 10.3788/AOS201434.0515001

## Fusion of Global and Local Various Feature for Facial Expression Recognition

Li Yaqian<sup>1,2</sup> Li Yingjie<sup>1</sup> Li Haibin<sup>1,2</sup> Zhang Qiang<sup>1</sup> Zhang Wenming<sup>1,2</sup>

<sup>1</sup>Key Laboratory of Industrial Computer Control Engineering of Hebei Province,  
Yanshan University, Qinhuangdao, Hebei 066004, China  
<sup>2</sup>National Engineering Research Center for Equipment and Technology of C. S. R.,  
Qinhuangdao, Hebei 066004, China

**Abstract** Principal component analysis (PCA) can only keep the global structure, while neighborhood preserving embedding (NPE) preserves the similarity between neighbor data, but ignores the difference between them. Focusing on the problems mentioned above, a feature extraction method is proposed by fusing global and local various feature, and is applied to facial expression recognition. PCA is used to preserve global structure and a local diversity scatter and a local similarity scatter is defined by manifold learning algorithms, combining with local maximum scatter difference criterion, the proposed method can efficiently preserve the variety of local manifold. The low dimensional feature is extracted by combining the global feature with local various feature for expression classification. The experiments on JAFFE and Cohn-Kanade facial expression databases indicate that compared with PCA, locality preserving projection (LPP), NPE and other methods, this method not only improves the recognition rate efficiently, but also needs the least dimensions when achieves the highest recognition rate, which demonstrates that this method is superior to others in recognition rate.

**Key words** machine vision; expression recognition; manifold learning; feature extraction

**OCIS codes** 100.5010; 150.0155; 070.5010

## 1 引 言

模式识别在很多领域都有广泛的应用前景,如

人机交互、安全、机器人制造、医疗等领域<sup>[1-3]</sup>。其中人脸表情识别(FER)的研究取得了很大进展,该

收稿日期: 2013-12-17; 收到修改稿日期: 2014-01-06

基金项目: 河北省自然科学基金(D2013203363)、河北省自然科学基金(D2014203153)

作者简介: 李雅倩(1982—),女,博士,副教授,主要从事计算机视觉方面的研究。E-mail: yaqian.li@gmail.com

\* 通信联系人。E-mail: hbli@ysu.edu.cn

课题已受到越来越多研究者的关注<sup>[4]</sup>。特征提取是表情识别中的核心步骤,其目标是提取人脸图像中可分性好的表情信息,同时达到数据降维的目的。目前用于人脸表情识别的几大特征提取方法主要有:基于小波<sup>[5]</sup>、基于主动外观模型(AAM)<sup>[6]</sup>、基于子空间<sup>[7-11]</sup>等方法。其中,基于小波的方法非常耗时间和耗内存,不适合用于建立快速高效的人机交互系统。基于 AAM 的方法虽然能获得较为可靠的表情特征,却具有计算复杂、初始参数难以获取等缺点。而基于子空间的方法尤其是流形学习方法不仅计算简单,而且可以解决人脸图像的高维问题。

传统无监督的子空间方法主要有两种思路:1) 保证降维前后样本的全局特征不变,典型代表为主成分分析(PCA)<sup>[7]</sup>。PCA 的目标是通过某种线性变换,将高维数据映射到低维空间中表示,期望在所投影维度上数据方差最大。不足之处在于其未探索数据的内在结构信息;2) 尽量保证相邻样本在降维前后流形结构不变,典型代表为局部线性嵌入(LLE)<sup>[8]</sup>、拉普拉斯本征映射(LE)<sup>[9]</sup>。近年来,有科学家提出人脸图像可能位于一个低维的非线性子流形上<sup>[12]</sup>,Chang 等<sup>[13]</sup>证明了人脸表情数据集在低维空间中具有流形的分布,可以将高维输入数据点映射到一个全局低维坐标系,既能降低数据维数、减少运算,又能很好地保留各类人脸样本的拓扑结构。由于 LLE 和 LE 是一种批处理模式,不能直接获取新样本的特征,这就是所谓的“out of sample”问题,致使其不能直接对新样本进行分类。为了克服“out of sample”问题,He 等<sup>[10]</sup>提出了邻域保持嵌入(NPE)、局部保持投影(LPP)<sup>[11]</sup>,并将其成功应用到人脸识别和表情识别领域。流形学习算法是通过寻找一种投影方向,使得在高维空间中邻域内相距比较近的点,投影到低维空间中仍然相距较近,较好地保持了数据的局部流形结构。Xu 等<sup>[14]</sup>得出在高维空间中,个体连续的表情变化图像会形成一个光滑的流形,但由于人脸外表差异的非连续性,不同个体的人脸表情图像会形成不同的表情流形。这些不同个体的人脸表情流形具有各自独特的复杂结构。因此表情流形之间不仅具有相似性,也具有差异性。而 LPP 和 NPE 都是通过最小化距离函数来保持数据的局部几何结构,导致距离比较近的点在目标函数中起主导作用,不能保证邻域内相距较远的点,投影后相距也较远,即忽略了局部流形结构的差异性。Wang 等<sup>[15]</sup>提出的局部保持主成分分析(LPPCA)算法将 LPP 与 PCA 结合,不仅实现了整体方差最

大化,而且保持了局部近邻结构不变,在故障检测中得到了很好的应用。LPPCA 算法不足之处在于提取局部特征时,仅考虑了数据的相似几何属性,忽略了邻域内数据间的差异性。

针对上述问题,提出了一种保持全局和局部多样性的特征提取算法(GLDPE)。该算法吸收有监督的局部结构和差异信息投影(S-LSDP)<sup>[16]</sup>的离散度思想,定义了局部差异离散度和局部相似离散度;然后基于文献[17]提出一个最大局部散度差信息保持准则,并在此基础上提取出局部结构的多样性信息,即差异性信息和相似性信息;最后结合 PCA 构造出保持全局与局部多样性特征的目标函数。这样不仅保留了原样本的大部分方差信息,而且有效地保持了局部流形结构的多样性。在 JAFFE 和 Cohn-Kanade 人脸表情数据库上分别采取随机和固定两种抽取方式进行特征提取,采用支持向量机(SVM)进行表情分类。实验结果表明:该算法与 LPP、NPE、PCA、LPPCA 相比,在识别率方面,两个数据库分别可达 83.6735%和 97.0833%,有效地提高了识别率;在降维方面,GLDPE 取得最高识别率时所需的投影向量个数最少,仅需 11 和 16 个很好地实现了维数约简。

## 2 GLDPE 算法描述

### 2.1 基本思想

假设样本集  $X = [x_1, x_2, \dots, x_N] \in R^M$  为原始高维空间中的样本, GLDPE 的基本思想是寻找一个投影矩阵  $W \in R^{M \times d}$ , 使得  $X$  通过投影  $y_i = W^T x_i (i = 1, 2, \dots, N)$  得到低维映射  $Y = [y_1, y_2, \dots, y_N] \in R^d (d < M)$ 。GLDPE 的优化目标可以分解为全局和局部两个目标函数,全局目标函数使映射得到的低维空间可以保留原始样本空间的大部分方差信息,实现了全局特征提取;局部目标函数通过定义两个离散度矩阵和建立一个最大局部散度差准则来提取局部多样性特征,即差异性特征和相似性特征。

### 2.2 全局特征提取

假设已知样本集  $X = [x_1, x_2, \dots, x_N]$ ,  $J(W)_{\text{global}}$  的目标是寻找  $d$  个投影向量  $w_1, w_2, \dots, w_d$ , 构成投影矩阵  $W$ , 使得通过投影映射  $y_i = W^T x_i (i = 1, 2, \dots, N)$  得到低维空间中原始样本特征,即<sup>[15]</sup>

$$J(\mathbf{W})_{\text{global}} = \max_{\mathbf{W}} \sum_{i=1}^N \|y_i - \bar{y}\|^2 = \max_{\mathbf{W}} \sum_{i=1}^N \mathbf{W}^T (x_i - \bar{x}) (x_i - \bar{x})^T \mathbf{W} = \max_{\mathbf{W}} \mathbf{W}^T \mathbf{C} \mathbf{W}, \quad (1)$$

式中

$$\bar{y} = (\sum_{i=1}^N y_i) / N, \quad \bar{x} = (\sum_{i=1}^N x_i) / N, \quad \mathbf{C} = \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T / N, \quad \mathbf{W} = [\omega_1, \omega_2, \dots, \omega_d].$$

GLDPE 的全局目标函数与 PCA 目标函数一致,是通过 K-L 变换将高维数据空间投影到低维空间,这种变换使得压缩前后的均方差最小,使低维空间具有很好的分辨能力。虽然它实现了全局结构的特征提取,但是并没有考虑样本点的局部结构,而且无法提取出样本的非线性结构特征。

## 2.3 局部特征提取

### 2.3.1 最大局部散度差准则

S-LSDP 算法在 Fisher 准则基础上提出了保持信息准则,该准则虽然有效地保持了样本间的差异和相似信息,但是它只有在相似离散度矩阵满秩时才有效,而在表情识别中该矩阵通常是不满秩的,并且 S-LSDP 在计算特征向量时运算复杂度较高。宋枫溪等<sup>[17]</sup>提出的最大散度差准则是区别于 Fisher 准则的另一种有利于分类的保持信息准则。是为了解决 Fisher 判别准则的奇异性问题而提出来的。与 Fisher 鉴别准则不同的是,它采用广义散度差(类间散度减去  $C$  倍的类内散度,  $C$  为模型参数,通常为非负实数)作为投影后数据的可分性度量,而不再沿用广义的 Rayleigh 熵,在人脸识别领域得到了较好的运用<sup>[18]</sup>。

受文献<sup>[17]</sup>的启发,建立一种新的保持局部结构差异信息和相似信息的准则,即最大局部散度差准则。它试图寻找一个最优投影方向,使得具有差异信息的高维模式样本沿该方向投影后能被最大限度地分开,而具有相似信息样本投影后尽量地聚集在一起。定义如下:

$$\max_{\mathbf{W}} J(\mathbf{W}) = \mathbf{W}^T \mathbf{S}_B \mathbf{W} - \mathbf{W}^T \mathbf{S}_M \mathbf{W} = \mathbf{W}^T (\mathbf{S}_B - \mathbf{S}_M) \mathbf{W}, \quad (2)$$

式中  $\mathbf{S}_B$  为局部差异离散度矩阵,  $\mathbf{S}_M$  为局部相似离散度矩阵。通过最大化局部差异离散度,同时最小化局部相似离散度,使得投影后的特征既能保持局部结构的差异性,又能保持局部结构的相似性。

### 2.3.2 基于局部差异离散度的局部差异特征提取

给定  $N$  个训练样本  $x_i \in R^n (i = 1, \dots, N)$ , 其中  $x_i$  代表第  $i (i = 1, \dots, N)$  个训练样本。则  $N$  个数据的流形结构中的差异性信息可由差异近邻图  $G_d = \{X, B\}$  来表示,其中  $X = [x_1, x_2, \dots, x_N]$  为训练样本,矩阵  $B$  中的元素度量了样本点之间的差异关系,元素  $B_{ij}$  定义如下:

$$B_{ij} = \begin{cases} \exp(-t / \|x_i - x_j\|^2), & x_i \in \Omega_{x_j}^k \text{ or } x_j \in \Omega_{x_i}^k \\ 0, & \text{other} \end{cases}, \quad (3)$$

式中  $\Omega_{x_i}^k$  代表  $x_i$  的  $k$  邻域点集,参数  $t$  的值为邻域中各个点距离和的平均值<sup>[19]</sup>。

为了使投影后的特征能更好地保持数据之间的差异信息,引入下面描述差异性信息的目标函数

$$\max_{\mathbf{W}} \sum_{ij} (y_i - y_j)^2 B_{ij}, \quad (4)$$

式中  $y_i = \mathbf{W}^T x_i (i = 1, 2, \dots, N)$ ,  $\mathbf{W}$  为投影矩阵,  $x_i \in \mathbf{X}$ 。

(3)式表明:若两个样本  $x_i$  和  $x_j$  在高维空间中相距较远,则两者的差异性权值较大。若投影后的特征  $y_i$  和  $y_j$  相距较近,则(4)式中的差异性权值  $B_{ij}$  提供了一个比较大的惩罚因子。最大化该函数是为了使在高维空间中差异性比较大的两个样本,投影到低维空间中仍然具有较大的差异性。

对  $\sum_{ij} (y_i - y_j)^2 B_{ij}$  进行代数变换可得

$$\begin{aligned} \frac{1}{2} \sum_{ij} (y_i - y_j)^2 B_{ij} &= \frac{1}{2} \sum_{ij} (\mathbf{W}^T x_i - \mathbf{W}^T x_j)^2 B_{ij} = \sum_{ij} (\mathbf{W}^T x_i B_{ij} x_i^T \mathbf{W} - \mathbf{W}^T x_j B_{ij} x_j^T \mathbf{W}) = \\ &= \mathbf{W}^T \mathbf{X} \mathbf{B}' \mathbf{X}^T \mathbf{W} - \mathbf{W}^T \mathbf{X} \mathbf{B} \mathbf{X}^T \mathbf{W} = \mathbf{W}^T \mathbf{X} (\mathbf{B}' - \mathbf{B}) \mathbf{X}^T \mathbf{W} = \mathbf{W}^T \mathbf{S}_B \mathbf{W}, \end{aligned} \quad (5)$$

$\mathbf{B}'$ 为对角阵且  $\mathbf{B}' = \sum_j \mathbf{B}_{ij}$ 。

将(5)式代入(4)式中,可得

$$\max_{\mathbf{W}} \mathbf{W}^T \mathbf{S}_B \mathbf{W}, \quad (6)$$

式中  $\mathbf{S}_B = \mathbf{X}(\mathbf{B}' - \mathbf{B})\mathbf{X}^T$ , 称之为局部差异离散度矩阵。

### 2.3.3 基于局部相似离散度的局部相似特征提取

类似差异离散度描述,对给定  $N$  个训练样本  $x_i \in R^n (i = 1, \dots, N)$ , 其中  $x_i$  代表第  $i (i = 1, \dots, N)$  个训练样本。则  $N$  个样本的空间结构的相似性信息可由相似近邻图  $G_s = \{X, S\}$  来表示,其中  $X = [x_1, x_2, \dots, x_N]$  为训练样本,  $S$  是一个  $N \times N$  的权值矩阵,由 NPE 中计算得到。定义如下:

$$\begin{aligned} \min \sum_i \|x_i - \sum_j \mathbf{S}_{ij} x_j\|^2 \\ \text{s. t. } \sum_j \mathbf{W}_{ij} = 1 \forall i \end{aligned} \quad (7)$$

为了更好地保持隐藏在数据间的相似信息,引入如下目标函数:

$$\min \sum_i (y_i - \sum_j \mathbf{S}_{ij} y_j)^2, \quad (8)$$

式中  $y_i = \mathbf{W}^T x_i (i = 1, 2, \dots, N)$ ,  $\mathbf{W}$  为投影矩阵,  $x_i \in X$ 。

(7)式表明:若两个样本  $x_i$  和  $x_j$  在高维空间中相距较近,则两者的相似性权值较大。若投影后的特征  $y_i$  和  $y_j$  相距较远,则(8)式中的  $\mathbf{S}_{ij}$  相似性权值提供了一个比较大的惩罚因子。最小化该函数是为了使在高维空间中相似性比较大的两个样本,投影到低维空间中仍然具有较大的相似性。

对  $\sum_i (y_i - \sum_j \mathbf{S}_{ij} y_j)^2$  进行代数变换可得<sup>[12]</sup>

$$\begin{aligned} \sum_i (y_i - \sum_j \mathbf{S}_{ij} y_j)^2 &= \sum_i (\mathbf{Z}_i)^2 = \mathbf{Z}^T \mathbf{Z} = \mathbf{y}^T (\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S}) \mathbf{y} = \mathbf{W}^T \mathbf{X} (\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S}) \mathbf{X}^T \mathbf{W} = \\ &= \mathbf{W}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{W} = \mathbf{W}^T \mathbf{S}_M \mathbf{W}. \end{aligned} \quad (9)$$

将(9)式代入(8)式中,可得

$$\min_{\mathbf{W}} \mathbf{W}^T \mathbf{S}_M \mathbf{W}, \quad (10)$$

式中  $\mathbf{S}_M = \mathbf{X}(\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S}) \mathbf{X}^T$ , 称之为局部相似离散度矩阵。

为了更好的保持样本的局部结构多样性属性,结合(1)、(6)和(10)式,局部目标函数定义如(2)式所示。其中  $\mathbf{W}^T \mathbf{S}_B \mathbf{W}$  和  $\mathbf{W}^T \mathbf{S}_M \mathbf{W}$  的含义分别如 2.3.2 和 2.3.3 所述。

## 2.4 GLDPE 目标函数

为了结合 PCA 和流形学习的优点,将具有多样性信息的局部特征提取思想融入 PCA 的目标函数中,使得 GLDPE 投影得到的低维空间能够获得更全面的特征信息。

综合考虑全局和局部目标函数,GLDPE 算法的目标函数定义为

$$J(\mathbf{W})_{\text{GLDPE}} = \max_{\alpha} \mathbf{W}^T \mathbf{C} \mathbf{W} + (1 - \alpha) [\mathbf{W}^T (\mathbf{S}_B - \mathbf{S}_M) \mathbf{W}] = \max_{\mathbf{W}} \mathbf{W}^T [\alpha \mathbf{C} + (1 - \alpha) (\mathbf{S}_B - \mathbf{S}_M) \mathbf{W}] = \max_{\mathbf{W}} \mathbf{W}^T \mathbf{S} \mathbf{W}, \quad (11)$$

式中  $\alpha$  为可调因子,表示全局特征和局部结构特征各自的权值。由(11)式求解可得到最优投影矩阵  $\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_d]$ 。为了消除特征之间的线性相关性,定义如下约束:  $\mathbf{W}^T \mathbf{W} = \mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵,即要求  $\mathbf{W}$  的列向量是正交的。结合该约束条件,利用拉格朗日乘子,将求解投影向量  $\mathbf{W}$  的问题转化为求解如下广义特征向量问题:

$$\mathbf{S} \mathbf{W} = \lambda \mathbf{W}, \quad (12)$$

式(12)中  $\mathbf{S}$  的前  $d$  个最大非零特征值所对应的特征向量构成的正交特征向量组即为最优投影矩阵  $\mathbf{W} = [\omega_1, \omega_2, \dots, \omega_d]$ , 在求解过程中无需对矩阵

$\mathbf{X}^T \mathbf{X}$  求逆,也就避免了  $\mathbf{X}^T \mathbf{X}$  的奇异性问题。

基于上述分析,GLDPE 算法步骤如下:

1) 创建差异近邻图  $G_d = \{X, B\}$  和相似近邻图  $G_s = \{X, S\}$ , 其中  $X = [x_1, x_2, \dots, x_N]$ , 表示样本集。在  $G_d = \{X, B\}$  中,当  $x_j$  在  $x_i$  的  $k$  邻域中,或者  $x_i$  在  $x_j$  的  $k$  邻域中时,则在两个样本点之间新增一条边,形成差异近邻图,度量任意两点之间的差异性信息的权值由  $B$  表示。相似近邻图的构建方法同上,  $S$  为度量相似近邻图中任意两点间的相似性信息的权值;

2) 计算差异权重  $B$  和相似权重  $S$ 。若差异近邻

图中的两样本点之间有边,则根据(3)式计算差异权值矩阵  $\mathbf{B}$ ;若相似近邻图中的两个样本点之间有边相连,则根据(7)式计算相似权值矩阵  $\mathbf{S}$ ;

3) 计算样本的协方差矩阵  $\mathbf{C}$ ,可由(1)式得到。计算差异离散度矩阵  $\mathbf{S}_B$  和相似离散度矩阵  $\mathbf{S}_M$ ,具体可通过(5)式和(9)式得到;

4) 计算最佳投影矩阵  $\mathbf{W}$ 。通过对(12)式的求解,可得到投影变换  $w_i (i = 1, 2, \dots, d)$ ;

5) 提取特征。对于任意训练样本  $x_i \in X$ ,经降维后可得  $y_i = \mathbf{W}^T x_i$ 。对于任意测试样本  $x^*$ ,投影到低维空间中的特征为  $y^* = \mathbf{W}^T x^*$ 。其中  $\mathbf{W}$  为投影变换矩阵。

## 2.5 算法复杂度分析

算法的复杂度主要由数据点的个数  $n$ 、原始维数  $D$ 、目标维数  $d$  以及算法涉及的参数如近邻点个数  $k$  (对基于谱图理论的方法)。所提算法中,建立近邻图需要  $O(Dn \log n)$ ,计算邻接权矩阵需要  $O(n^2)$ ,计算协方差矩阵需要  $O(nD)$ ,对  $n \text{ pixel} \times n \text{ pixel}$  矩阵进行特征分析,由于它们的  $n \text{ pixel} \times n \text{ pixel}$  矩阵通常是稀疏的,所以需要的时间复杂度为  $O(pn^2)$  (这里  $p$  是稀疏矩阵中非零元和零元的比率)。综合上述分析,表 1 列出了各算法的时间复杂度。

表 1 算法的时间复杂度

Table 1 Time complexity of all the algorithms

Algorithms	Time complexity
PCA	$O(nD) + O(D^3)$
NPE	$O(Dn \log n) + O(n^2) + O(pn^2)$
LPP	$O(Dn \log n) + O(n^2) + O(pn^2)$
LPPCA	$O(Dn \log n) + O(nD) + O(n^2) + O(pn^2)$
GLDPE	$2O(Dn \log n) + O(nD) + 2O(n^2) + O(pn^2)$



图 1 JAFFE 人脸表情库的人脸表情图像示例

Fig. 1 Examples of seven facial expression images in JAFFE



图 2 Cohn-Kanade 人脸表情库的人脸表情图像示例

Fig. 2 Examples of seven facial expression images in Cohn-Kanade

## 3.2 实验结果和分析

图 3(a) 和 (b) 分别为五种算法在 JAFFE 和 Cohn-Kanade 人脸表情数据库上的随着维数变化的

## 3 实验分析

为了验证 GLDPE 算法的有效性,本实验将在 JAFFE 和 Cohn-Kanade 人脸表情数据库上对 PCA、LPP、NPE、LPPCA、GLDPE 进行比较。所使用的分类器为台湾大学林智仁教授开发的 lib-svm<sup>[20]</sup>。

### 3.1 数据库介绍

JAFFE 人脸表情数据库是日本 ATR 建立的专门用于表情识别研究的基本表情数据库<sup>[21]</sup>。该数据库包含了 213 幅(每幅图像大小为  $256 \text{ pixel} \times 256 \text{ pixel}$ )日本女性的头部。数据库中共有 10 个人,每个人有 7 种表情(生气、沮丧、高兴、悲伤、中性脸、惊奇、恐惧)。每个人每种表情 2~3 幅。在预处理阶段,对图像进行手动裁剪获得只包含人脸的部分,并归一化为  $32 \text{ pixel} \times 32 \text{ pixel}$ 。图 1 为经过预处理后的图像示例,从左到右依次为:生气、沮丧、恐惧、高兴、悲伤、惊奇和中性。此数据库中每种表情至少有 29 幅图像,因此从每类中选取 29 张来进行实验。每次实验,每类随机选取 15 张作为训练集,共 105 张;余下的作为测试集,共 98 张。

Cohn-Kanade 数据库是 CMU 机器人研究所和心理系于 2000 年共同建立的人脸表情数据库,它包含了 100 个由 18~30 岁的成年人近 500 张不同表情序列。其中 69% 为女性,35% 为非裔美洲人,3% 为亚洲和拉丁美洲人<sup>[22]</sup>。在预处理阶段,将每张图像大小归一化为  $64 \text{ pixel} \times 64 \text{ pixel}$ 。经过预处理后的图像示例如图 2 所示,从左到右依次为:生气、沮丧、恐惧、高兴、悲伤、惊奇。在每类表情中选取 20 个人,每个人四种不同强度的表情作实验二的数据集。在此数据集中,每类选取每个人的 2 张表情作为训练集,共 240 张;余下的 240 张作为测试集。

识别率曲线图。表 2 总结了在两个数据库上每个算法取得的最高识别率以及相应的维数和所需时间。本实验中共有三个参数: $K$ 、 $K_1$ 、 $\alpha$ 。需要说明的是在 NPE、LPP、LPPCA、GLDPE 中,都涉及邻域选择问题,由于至今为止还无法从理论上给出最优选择,因此为了更好的评价各种算法的性能,实验中的  $K$ 、 $K_1$  均在  $[0, 50]$  上进行搜索选取, $\alpha$  是在  $[0.1, 0.9]$  中搜索选取。

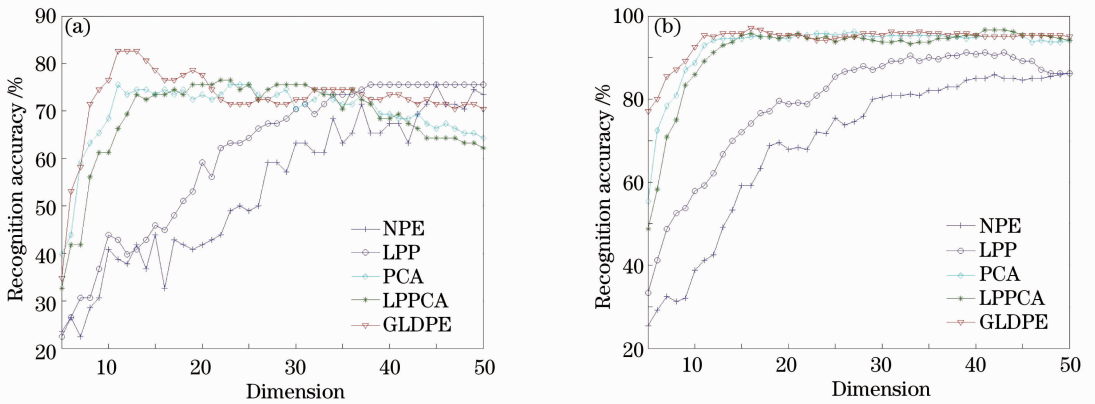


图 3 (a), (b) 分别为在 JAFFE 和 Cohn-Kanade 数据库上识别率

Fig. 3 (a), (b) are recognition rates for JAFFE database and Cohn-Kanade database respectively

表 2 不同算法在 JAFFE 和 Cohn-Kanade 数据库上的最佳识别结果

Table 2 Best recognition accuracy achieved by all methods on the JAFFE database and the Cohn-Kanade database

Database	JAFFE			Cohn-Kanade			
	Method	Dimension	Accuracy / %	Time / s	Dimension	Accuracy / %	Time / s
	NPE	45	75.5102	2.9448	50	86.2500	0.9524
	LPP	38	75.5102	2.8180	33	90.4167	0.6107
	PCA	11	75.5102	0.5540	27	96.2500	0.3945
	LPPCA	22	75.5306	3.3409	41	96.6670	3.0998
	GLDPE	11	83.6735	3.3791	16	97.0833	3.1280

由表 2 可以看出,在 JAFFE 数据库上,GLDPE 的识别率比 PCA、LPP、NPE、LPPCA 算法识别率提高至少 8 个百分点,在 Cohn-Kanade 数据库上比传统流形学习算法有明显的提高,比 PCA 和改进算法 LPPCA 略有提高。

由图 3 中(a)、(b)对比可知:在 JAFFE 数据库中 GLDPE 的结果比另外几种传统算法高出很多;在 Cohn-Kanade 数据库中的结果只是略优于其他几种算法,可能是因为 JAFFE 数据库中训练集样本个数较少,而 Cohn-Kanade 数据库中训练样本相对较多,说明 GLDPE 在处理小样本问题上具有优越性。

从维数约简的目的来看,在图 3(a)和(b)中,GLDPE 达到较高识别率时所需的投影向量个数明显少于其他方法,再一次证明了文献[11]中的结论:人脸表情位于一个低维的流形上。说明 GLDPE 方法不仅可以提取出嵌入在高维数据中有意义的低维结构特征,而且可以提高表情识别系统的分类效果。

由表 1、表 2 得知,由于 GLDPE 算法需要对局部与全局特征进行特征提取,局部提取时同时考虑到邻域样本的相似性和差异性,计算量有所增加,时间消耗也有所增加,但都在一个数量级上,且相差甚微,相对于识别率提高的幅度来说,此计算代价是可

以接受的。

## 4 结 论

提出了一种新的特征提取方法 GLDPE,并将其应用到了表情识别中。该方法不仅充分保持了样本的全局特性,而且有效地提取出局部流形结构的差异性和相似性。在 JAFFE 和 Cohn-Kanade 人脸表情数据库上进行的实验证实了该算法在识别率、处理小样本问题上的有效性和优越性。但是实验中参数  $K$  是通过实验得出的结果,是相对耗时的;并且在不同数据库中选择也不同,如何从理论上定义局部性,使得算法具有快速性、稳定性并取得最佳实验结果,是今后课题研究的重点。

## 参 考 文 献

- Zhang Su, Wang Wensheng. Optical correlation recognition of the moving target in cluttered background [J]. Acta Optica Sinica, 2012, 32(1): 0107001.  
张 肃, 王文生. 复杂背景下运动目标的光学相关识别[J]. 光学学报, 2012, 32(1): 0107001.
- Jin Biao, Hu Wenlong, Wang Hongqi. Moving-objects interaction recognition based on the spatial-temporal semantic information [J]. Acta Optica Sinica, 2012, 32(5): 0515002.  
金 标, 胡文龙, 王宏琦. 基于时空语义信息的视频运动目标交互行为识别方法[J]. 光学学报, 2012, 32(5): 0515002.
- Wang Wenfeng, Zhu Shuhua, Feng Yihao, et al.. Parallel edges detection from remote sensing image using local orientation coding

- [J]. *Acta Optica Sinica*, 2012, 32(3): 0315001.
- 王文锋, 朱书华, 冯以浩, 等. 基于局部方向编码的遥感影像平行边缘识别[J]. *光学学报*, 2012, 32(3): 0315001.
- 4 Guofeng Zou, Wang Kejun, Yuan Lei, *et al.*. New research advances in facial expression recognition [C]. the IEEE 25th Chinese Control and Decision Conference (CCDC), Guiyang, 2013: 3403–3409.
- 5 Lu Guanming, Li Xiaonan, Li Haibo. Research on recognition for facial expression of pain in neonates [J]. *Acta Optica Sinica*, 2008, 28(11): 2109–2114.
- 卢官明, 李晓南, 李海波. 新生儿疼痛面部表情识别方法的研究[J]. *光学学报*, 2008, 28(11): 2109–2114.
- 6 Yi Jizheng, Mao Xia, Xue Yuli. Facial expression recognition based on feature point vector and texture deformation energy parameters [J]. *Journal of Electronics & Information Technology*, 2013, 35(10): 2403–2410.
- 易积政, 毛 峡, 薛雨丽. 基于特征点矢量与纹理形变能量参数融合的人脸表情识别[J]. *电子与信息学报*, 2013, 35(10): 2403–2410.
- 7 H Abdi, L J Williams. Principal component analysis [J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2010, 2(4): 433–459.
- 8 J B Tenenbaum, V De Silva, J C Langford. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500): 2319–2323.
- 9 M Belkin, P Niyogi. Laplacian eigenmaps and spectral techniques for embedding and clustering [C]. *NIPS*, 2001, 14: 585–591.
- 10 X He, D Cai, S Yan, *et al.*. Neighborhood preserving embedding [C]. Tenth IEEE International Conference on Computer Vision, 2005, 2: 1208–1213.
- 11 X He, S Yan, Y Hu, *et al.*. Face recognition using laplacianfaces [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328–340.
- 12 Huang Hong, Li Jianwei, Feng Hailiang. Facial expression recognition based on supervised kernel local linear embedding [J]. *Optics and Precision Engineering*, 2008, 16(8): 1471–1477.
- 黄 鸿, 李见为, 冯海亮. 基于有监督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.
- 13 Y Chang, C Hu, M Turk. Manifold of facial expression [C]. *AMFG*, 2003: 28–35.
- 14 Xu Shuang, Jia Yunde. Facial expression manifold based on expression similarity [J]. *Journal of Software*, 2009, 20(8): 2191–2198.
- 续 爽, 贾云得. 基于表情相似性的人脸表情流形[J]. *软件学报*, 2009, 20(8): 2191–2198.
- 15 Wang Jian, Feng Jian, Han Zhiyan. Locally preserving PCA method based on manifold learning and its application in fault detection [J]. *Control and Decision*, 2013, 28(5): 683–687.
- 王 健, 冯 健, 韩志艳. 基于流形学习的局部保持 PCA 算法在故障检测中的应用[J]. *控制与决策*, 2013, 28(5): 683–687.
- 16 Gao Quanxue, Xie Deyan, Xu Hui, *et al.*. Supervised feature extraction based on information fusion of local structure and diversity information [J]. *Acta Automatica Sinica*, 2010, 36(8): 1107–1114.
- 高全学, 谢德燕, 徐 辉, 等. 融合局部结构和差异信息的监督特征提取算法[J]. *自动化学报*, 2010, 36(8): 1107–1114.
- 17 Song Fengxi, Yang Jingyu, Liu Shuhai, *et al.*. Face recognition based on the multiple-class maximum scatter difference [J]. *Acta Automatica Sinica*, 2006, 32(3): 378–385.
- 宋枫溪, 杨静宇, 刘树海, 等. 基于多类散度差人脸表示方法[J]. *自动化学报*, 2006, 32(3): 378–385.
- 18 Tian Yumin, Yun Yane, Ma Tianjun. Discriminant neighborhood preserving embedding algorithm for face recognition [J]. *Journal of Xidian University*, 2011, 38(3): 24–28.
- 田玉敏, 云艳娥, 马天骏. 判别近邻保持嵌入人脸识别[J]. *西安电子科技大学学报*, 2011, 38(3): 24–28.
- 19 Tan Rui, Chen Xiuhong. Semi-supervised locality preserving protection dimensionality reduction method [J]. *Computer Engineering*, 2012, 38(6): 181–183.
- 谈 锐, 陈秀宏. 半监督的局部保留投影降维方法[J]. *计算机工程*, 2012, 38(6): 181–183.
- 20 C C Chang, C J Lin. LIBSVM: a library for support vector machines [J]. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2011, 2(3): 1–30.
- 21 M Lyons, S Akamatsu, M Kamachi, *et al.*. Coding facial expressions with gabor wavelets [C]. *Proceedings of Third IEEE International Conference on Automatic Face and Gesture Recognition*, Nara, Japan, 1998. 200–205.
- 22 T Kanade, J F Cohn, Y Tian. Comprehensive database for facial expression analysis [C]. *Proceedings of Fourth IEEE International Conference on Automatic Face and Gesture Recognition*, Grenoble, France, 2000: 46–53.

栏目编辑：张浩佳