

文章编号:1001-9081(2009)05-1416-03

## 一种新的有监督保局投影人脸识别算法

刘敏<sup>1</sup>, 李晓东<sup>2</sup>, 王振海<sup>1</sup>

(1. 临沂师范学院 信息学院, 山东 临沂 276005; 2. 东南大学 复杂工程系统测量与控制教育部重点实验室, 南京 210096)  
(sningjing@163.com)

**摘要:**为了充分利用样本的类别信息,提出了一种新的有监督保局投影人脸识别算法(NSLPP)。首先,把类间散布矩阵融入到传统保局投影算法的目标函数中,修改目标函数,并基于新的目标函数得到变换矩阵;然后用线性鉴别的思想筛选出变换矩阵中的最优基向量,构成最终的变换矩阵,把训练样本和测试样本投影到有最优基向量构成的子空间得到训练样本和测试样本的特征;最后采用最近邻分类器分类,在 ORL 和 FERET 人脸库上的测试结果表明,NSLPP 算法具有较好的识别性能。

**关键词:**人脸识别;有监督保局投影;线性鉴别;有监督学习

**中图分类号:** TP391.41 **文献标志码:** A

## New supervised locality-preserving projections algorithm for face recognition

LIU Min<sup>1</sup>, LI Xiao-dong<sup>2</sup>, WANG Zhen-hai<sup>1</sup>

(1. School of Information, Linyi Normal University, Linyi Shandong 276005, China;

2. Key Laboratory of Measurement and Control of Complex Systems of Engineering, Southeast University, Nanjing Jiangsu 210096, China)

**Abstract:** In order to make full use of the classification information of samples to get optimal features, a new Supervised Locality Preserving Projections (NSLPP) algorithm for face recognition was proposed. Between-class scatter matrix was embedded in the objective function of original locality preserving projections, and the transformation matrix could be obtained based on the modified objective function. Subsequently, according to the idea of linear discriminant, the optimal base vectors of the transformation matrix were selected to form the final transformation matrix. As a result, the features of training samples and testing samples were got by projecting them on the subspace spanned by optimal base vectors. Finally, Nearest Neighborhood (NN) algorithm was used to construct classifiers. Experiments on ORL and FERET face database show that the recognition performance of NSLPP is effective.

**Key words:** face recognition; supervised locality-preserving projections; linear discrimination; supervised learning

### 0 引言

人脸识别是生物特征鉴别技术的一个主要方向,它涉及图像处理、模式识别、计算机视觉等多个研究领域,具有十分广泛的应用前景,多年来一直是一个研究热点<sup>[1-3]</sup>。寻找有效的特征是解决识别问题的关键,比较常见的人脸特征提取方法有 Eigenface<sup>[4]</sup>和 Fisherface<sup>[5]</sup>。Eigenface 将主成分分析(Principal Component Analysis, PCA)应用于人脸识别,通过提取人脸图像的主成分进行识别。Eigenface 基于重建准则,即重建误差最小,它无法揭示数据的局部结构,当人脸的光照、表情产生比较大的变化时,其识别率一般不是十分理想。Fisherface 属于有监督识别方法,利用线性鉴别分析(Linear Discriminant Analysis, LDA)寻找使类间距和类内距比值最大化的投影方向,获得了较好的识别效果。然而,当样本数目小于样本维数时, Fisherface 将出现小样本问题,所以一般先采用 PCA 降维,然后再用 LDA 提取特征进行识别。

保局投影(Locality Preserving Projections, LPP)<sup>[6]</sup>是一种新的子空间分析方法,它是非线性方法 Laplacian Eigenmap 的线性近似,既解决了 PCA 等传统线性方法难以保持原始数据非线性流形的缺点<sup>[7]</sup>,又解决了非线性方法难以获得新样本点低维投影的缺点。但 LPP 算法是一种无监督的学习方法,

当人脸图像的光照、姿态、表情等发生变化时, LPP 的识别率会下降<sup>[8]</sup>。目前已有改进的算法<sup>[9-10]</sup>,但是这些算法都没有较好地考虑样本的类别信息。文献[11]提出了一种监督式 LPP 算法(Supervised LPP, SLPP),但是此方法是在用无监督的 LPP 方法得到变换矩阵后,再利用线性鉴别的思想选取最优的基向量。它虽然提高了识别率,但是还没有融入真正的有监督的思想。

鉴于以上分析,本文提出了一种新的有监督保局投影人脸识别算法(New Supervised LPP, NSLPP)。通过修改保局投影算法的目标函数,把类间散布矩阵融入到目标函数,并基于此得到变换矩阵;接着利用线性鉴别方法进一步选择最优的基向量构成变换矩阵。基于 ORL (Olivetti Research Laboratory)和 FERET(Face Recognition Technology)人脸数据库上的实验结果证明了本文算法是有效的。

### 1 保局投影

设有  $l$  个训练样本  $X = \{x_i\}_{i=1}^l \in \mathbf{R}^m$ , 保局投影的思想是通过一定的性能目标函数来寻找线性变换矩阵  $W$ , 以实现我对高维数据的降维:

$$y_j = W^T x_j; j = 1, 2, \dots, l \quad (1)$$

收稿日期:2008-11-20;修回日期:2009-01-31。

作者简介:刘敏(1970-),女,山东莒县人,副教授,硕士,主要研究方向:智能控制、图像处理; 李晓东(1974-),男,山东苍山人,讲师,博士,主要研究方向:智能控制、人脸检测与识别; 王振海(1972-),男,山东苍山人,讲师,硕士,主要研究方向:图像与视频处理、多媒体。

变换矩阵可以通过最小化如下目标函数来得到:

$$\min \left( \sum_{i,j} (\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j)^2 S_{ij} \right) \quad (2)$$

其中  $S$  是权值矩阵,可采用  $K$  近邻法来定义:

$$S_{ij} = \begin{cases} \frac{\exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2)}{t}, & \mathbf{x}_j \text{ 是 } \mathbf{x}_i \text{ 的 } k \text{ 个近邻点} \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中  $t$  是一个大于 0 的常量。

从目标函数式(2)可看出,降维后的特征空间能够保持原始高维空间的局部结构。对式(2)进行代数变换:

$$\begin{aligned} \frac{1}{2} \sum_{i,j} (\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j)^2 S_{ij} &= \\ \sum_{i,j} \mathbf{W}^T \mathbf{x}_i \mathbf{D}_{ij} \mathbf{x}_i^T \mathbf{W} - \sum_{i,j} \mathbf{W}^T \mathbf{x}_i S_{ij} \mathbf{x}_j^T \mathbf{W} &= \\ \mathbf{W}^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W} &= \mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} \end{aligned} \quad (4)$$

其中  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_l]$ ,  $\mathbf{D}$  是  $l \times l$  对角阵,  $\mathbf{D}_{ii} = \sum_j S_{ij}$ ,  $\mathbf{L} = \mathbf{D} - \mathbf{S}$  为拉普拉斯矩阵。 $\mathbf{D}_{ii}$  越大,表明  $y_i$  越“重要”。

能够使式(4)取最小值的变换矩阵  $\mathbf{W}$  可以通过求解如下的广义本征值问题而得到:

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{W} \quad (5)$$

式(5)的  $d$  个最小的非零特征值所对应的特征向量构成投影矩阵  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$ 。

## 2 新的有监督保局投影算法

LPP 算法自提出后被广泛应用于人脸识别中,但是该算法得到的特征是最佳描述特征而不是最佳分类特征,是一种无监督人脸识别方法,没有考虑样本的类别信息。本文借鉴文献[12]的鉴别保局投影方法(Discriminant LPP, DLPP),修改了传统 LPP 方法的目标函数,使之成为一种有监督的 LPP 方法,具体做法如下。

设有  $l$  个训练样本  $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^l \in \mathbf{R}^m$ , 共有  $C$  类,类标分别为  $c_1, c_2, \dots, c_C$ , 第  $i$  类的样本数是  $n_i (i = 1, 2, \dots, C)$ 。

所有样本均值向量:

$$\mathbf{u} = \frac{1}{l} \sum_{i=1}^l \mathbf{y}_i \quad (6)$$

第  $i$  类样本的均值向量:

$$\mathbf{u}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{y}_j \quad (7)$$

样本的类间散布矩阵:

$$\mathbf{S}_b = \sum_{i=1}^C n_i (\mathbf{u}_i - \mathbf{u})(\mathbf{u}_i - \mathbf{u})^T \quad (8)$$

则改进后的保局投影算法的目标函数为:

$$J = \frac{\sum_{i,j=1}^l (\mathbf{y}_i - \mathbf{y}_j)(\mathbf{y}_i - \mathbf{y}_j)^T S_{ij}}{\mathbf{S}_b} \quad (9)$$

由式(1),目标函数可以改写为:

$$J(\mathbf{W}) = \frac{\sum_{i,j=1}^l \|\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j\|^2 S_{ij}}{\sum_{i=1}^C n_i \left\| \frac{1}{n_i} \sum_{k=1}^{n_i} \mathbf{W}^T \mathbf{x}_k - \frac{1}{l} \sum_{m=1}^l \mathbf{W}^T \mathbf{x}_m \right\|^2} = \frac{\text{tra}(\mathbf{W}^T \mathbf{S}_b \mathbf{W})}{\text{tra}(\mathbf{W}^T \mathbf{S}_b \mathbf{W})} \quad (10)$$

其中:  $\mathbf{S}_L = \sum_{i,j=1}^l (\mathbf{y}_i - \mathbf{y}_j)(\mathbf{y}_i - \mathbf{y}_j)^T S_{ij}$ 。

然后通过求解特征值问题:

$$\mathbf{S}_L \mathbf{w}_i = \lambda_i \mathbf{S}_i \mathbf{w}_i; \lambda_1 < \lambda_2 < \dots < \lambda_d \quad (11)$$

即可获得最优投影矩阵  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$ 。

改进后的目标函数的意义就是在保持得到样本的最佳描述特征的同时尽量扩大不同样本点之间的距离,因此改进后的算法考虑了样本的类别信息,将更有利于识别性能的改善,但是目标函数的分子项只是强调了最佳描述特征,没有考虑缩小类内样本间的距离,当光照、姿态、表情等导致图像的类内差异超过图像类间差异时,一些人脸图像就会偏离它的类中心,而靠向其他类。为了进一步缩小样本的类内距离,压制图像之间的与识别信息无关的差异,本文用线性鉴别的思想进一步筛选  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$  中的基向量,构成新的投影子空间,具体算法如下。

令  $C$  为所有样本可分的类数,  $n_j$  为属于第  $j$  类的样本数,  $\mathbf{u}_j$  为第  $j$  类样本的平均向量,  $\mathbf{u}$  为所有样本的平均向量,  $\overline{\mathbf{S}_{bi}}$  为第  $i$  个基向量的一维投影子空间所对应的类内散布矩阵,  $\overline{\mathbf{S}_{bi}}$  为第  $i$  个基向量的一维投影子空间所对应的类间散布矩阵。

用  $\text{Var}_{\text{inter}}(\mathbf{w}_i)$  表示第  $i$  个基向量  $\mathbf{w}_i$  所代表的类间差异,  $\text{Var}_{\text{intra}}(\mathbf{w}_i)$  表示第  $i$  个基向量  $\mathbf{w}_i$  所代表的类内差异,其定义如下:

$$\begin{cases} \text{Var}_{\text{inter}}(\mathbf{w}_i) = \det(\overline{\mathbf{S}_{bi}}) = \det \left( \sum_{j=1}^C (\tilde{\mathbf{u}}_j - \tilde{\mathbf{u}})(\tilde{\mathbf{u}}_j - \tilde{\mathbf{u}})^T \right) \\ \tilde{\mathbf{u}}_j = \mathbf{w}_i^T \mathbf{u}_j \\ \tilde{\mathbf{u}} = \mathbf{w}_i^T \mathbf{u} \end{cases} \quad (12)$$

$$\begin{cases} \text{Var}_{\text{intra}}(\mathbf{w}_i) = \det(\overline{\mathbf{S}_{ai}}) = \det \left( \sum_{j=1}^C \sum_{i \in n_j} (\tilde{\mathbf{x}}_i - \tilde{\mathbf{u}}_j)(\tilde{\mathbf{x}}_i - \tilde{\mathbf{u}}_j)^T \right) \\ \tilde{\mathbf{x}}_i = \mathbf{w}_i^T \mathbf{x}_i \\ \tilde{\mathbf{u}}_j = \mathbf{w}_i^T \mathbf{u}_j \end{cases} \quad (13)$$

从而可根据式(14)对  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$  进行基向量选择。

$$J = \arg \max \left( \frac{\text{Var}_{\text{inter}}(\mathbf{w}_i)}{\text{Var}_{\text{intra}}(\mathbf{w}_i)} \right) \quad (14)$$

综上,本文算法步骤归纳如下:

- 1) 按式(11)的最优变换矩阵  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$ ;
- 2) 按式(12)、(13)分别计算  $\text{Var}_{\text{inter}}(\mathbf{w}_i)$  和  $\text{Var}_{\text{intra}}(\mathbf{w}_i)$ ;
- 3) 按式(14)从  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$  的  $d$  个基向量筛选出最优的  $p$  个基向量构造新的变换矩阵  $\mathbf{V}$ ;
- 4) 根据  $\mathbf{y}_j = \mathbf{V}^T \mathbf{x}_j (j = 1, 2, \dots, l)$  计算所有样本的特征向量;
- 5) 根据最近邻分类器进行分类识别。

## 3 实验及结果分析

### 3.1 ORL 人脸数据库实验

将本文方法在 ORL 人脸库上进行测试,该人脸库包含 40 个人,每个人有 10 幅图像。图像为单一深色背景的正脸图像,包含了一定的光照变化、表情变化(睁眼和闭眼,笑与不笑)、面部细节变化(戴眼镜与不戴眼镜)以及一定范围内的深度旋转,这些图像大小均为  $112 \times 92$  像素,其部分人脸如图

1 所示。

实验中对每个人任意选取 5 幅图像作为训练样本,其余的 5 幅图像用来测试识别方法的性能,此过程重复 10 次,取 10 次的平均值作为最终识别结果。本文方法与常用的人脸识别方法如 PCA、LDA、LPP、SLPP 等的性能进行比较。在 LDA、LPP、SLPP、NSLPP 算法中都先用 PCA 算法进行降维,并且设定降维后的维数都是 30,实验结果如图 2 所示。



图 1 ORL 人脸库中的部分图像

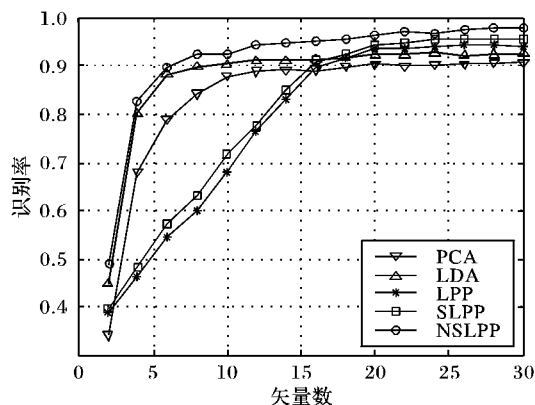


图 2 鉴别矢量个数变化时的识别率

从图 2 可以看出,本文算法 NSLPP 明显优于 PCA、LDA、LPP、SLPP 等方法的性能。由于本文算法把类间散布矩阵融入到目标函数中,较好地运用了样本的类别信息,因此,在鉴别矢量个数较少时,其识别率比 SLPP 算法有较大提高。

图 3 是当训练样本的个数变化时本文方法与 DLPP、SLPP 算法的最高识别率的比较。从图中可以看出本文方法明显优于 SLPP 和 DLPP 算法,当训练样本数为 8 时,本文算法的识别率达到 100%。




图 3 训练样本个数不同时的识别率

### 3.2 FERET 人脸数据库实验

本文算法也在著名的 FERET 人脸数据库<sup>[13-14]</sup>的一个子集上进行识别性能的验证。该子集包括 200 个人的 1400 张人脸图像,每人 7 张。数据库中的人脸图像包括人脸表情、光照、姿态等的变化。为了简化识别过程,对每张人脸图像进行

人工裁剪并标准化为  $40 \times 40$  像素大小。标准化后的部分人脸图像如图 4 所示。

实验中任意选取每人的三幅图像用于训练,其余 4 副图像用于测试,最后选取 10 次的平均值作为识别结果。实验中,LDA、LPP、SLPP、DLPP、NSLPP 等方法都是用 PCA 方法先降维,并统一设定降维后的维数为 15。本文方法与 PCA、LDA 等方法的比较结果如表 1 所示。

从表 1 中可以看出,在人脸表情、光照、姿态等的变化较大的 FERET 人脸库中,本文方法仍然具有较好的识别性能。



图 4 FERET 人脸库中的部分图像

表 1 各种方法的首选识别率比较

方法	识别率/%
PCA	50.38
LDA	53.13
LPP	54.20
SLPP	58.56
DLPP	61.23
NSLPP	65.27

## 4 结语

为了在使用 LPP 算法时更好地利用样本的类别信息,从而获得最优鉴别力的特征向量,本文提出了一种新的有监督保局投影人脸识别方法 NSLPP。根据线性鉴别的思想,把类间散布矩阵引入到 LPP 算法的目标函数中,并结合 SLPP 算法的思想,使本文算法能在扩大不同类样本间的距离的同时也能减小同类样本间的距离。SLPP 算法是在用无监督的 LPP 方法得到变换矩阵后,再利用线性鉴别的方法筛选基向量;而本文方法是先对 LPP 方法应用线性鉴别的思想得到变换矩阵,然后再进行线性鉴别筛选,因而识别性能优于 SLPP 方法。在 ORL 和 FERET 人脸数据库上的实验结果表明本文算法具有较好的识别性能。

### 参考文献:

- [1] ZHAO W, CHELLAPPA R, PHILLIPS P J, *et al.* Face recognition: A literature survey[J]. ACM Computing Surveys, 2003, 35(4): 399-458.
- [2] 庞春江,高婉青. 基于模糊混沌神经网络的人脸识别算法[J]. 计算机应用, 2008, 28(6): 1549-1551.
- [3] 徐倩,邓伟. 基于局部特征的自适应加权 2DPCA 的人脸识别[J]. 计算机应用, 2008, 28(5): 1267-1271.
- [4] TURK M, PENTLAND A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
- [5] 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.
- [6] HE XIAO-FEI, YAN SHUI-CHENG, HU YU-XIAO, *et al.* Face recognition using laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.

(下转第 1422 页)

$$f(x) = \text{sgn} \left( \sum_{i=1}^l \alpha_i K(x_i, x) - \rho \right)$$

由任一满足  $0 < \alpha_i < 1/m$  的样本  $x_i$  可计算出参数  $\rho =$

$$\sum_{j=1}^l \alpha_j K(x_i, x_j)。$$

## 2.2 基于单类支持向量机实现多分类

采用的方法是将每一类训练样本均进行单类支持向量机的运算,得到每类样本的决策函数  $f(x)$ ,然后将测试样本输入到每类的决策函数中,根据决策函数输出的最大值判断该测试样本所属的类别。决策函数如式(16)所述,  $c$  为类别号,  $L$  为类别数。采用径向基函数 RBF 为核函数。实际中  $\delta$  取值越小包含的训练样本的空间越紧密。

$$f_c(x) = \sum_{i=1}^l \alpha_i^c K(x_i^c, x); c = 1, \dots, L \quad (16)$$

## 3 实验结果及分析

表 2 音频数据库组成

### 3.1 实验数据库

音频数据库包括语音、音乐、带背景音的语音、环境音和静音 5 部分。语音库包含 6 个国家的语言;音乐库包含古典、流行、爵士、儿歌等不同音乐类型;含背景音的语音主要包括含音乐和环境音的语音;城市交通、人群、娱乐场所等地的音频记录组成环境音数据库,数据库组成如表 2 所示。所有的数据采样率是 16 KHz, 16 位精度,存储格式为 wav 格式。总的容量 500 min,特征提取后得到 30000 个片段。每类数据样本 1/3 用于训练模型,2/3 用于测试。

分类精度定义如下:

$$\text{分类精度} = \frac{\text{正确分类的样本数}}{\text{样本总数}} \quad (17)$$

### 3.2 实验结果

为评价提出算法的有效性,使用贝叶斯、隐马尔可夫模型和神经网络完成同样的音频分类任务。实验结果如表 3 所示。从结果中可以发现,环境音和含背景音的语音分类精度低于其他音频类型,因为在它们其中混有多种音频成分;而对纯语音、音乐和静音的分类精度较高。在所有的分类结果中,单类支持向量机的分类精度超过其他分类器,这是因为 SVM 具有很好的非线性分类性能。

## 4 结语

本文将单类支持向量机应用于音频分类,将音频信号分为 5 类:纯语音、音乐、带背景音的语音、环境音和静音。实验结果表明,使用单类支持向量机解决传统多分类任务中参数

选择和模型训练复杂的难题,分类性能高于其他常用分类器,平均分类精度为 90%,取得了比较满意的结果。下一步的工作是扩展音频分类类型和研究基于内容的音频分割。

表 3 5 种音频类型的分类精度 %

音频类型	分类器			
	贝叶斯	隐马尔可夫模型	神经网络	单类支持向量机
纯语音	90.3	94.7	98.2	98.7
音乐	82.5	86.0	91.7	93.6
环境音	65.6	68.1	71.6	75.5
含背景音语音	73.1	78.3	80.4	85.0
静音	91.1	93.2	94.5	96.7

## 参考文献:

- [1] SAUNDERS J. Real-time discrimination of broadcast speech/music [C]// Proceedings of the IEEE Conference on Acoustics, Speech, and Signal Processing: ICASSP 96. Washington, DC: IEEE Computer Society, 1996, 2: 993-996.
- [2] SCHEIRER E, SLANEY M. Construction and evaluation of a robust multifeature music/speech discriminator [C]// Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing: ICASSP 97. Washington, DC: IEEE Computer Society, 1997, 2: 1331.
- [3] WOLD E, BLUM T, KEISLAR D, et al. Content-based classification search and retrieval of audio [J]. IEEE Multimedia Magazine, 1996, 3(3): 27-36.
- [4] CORTIZO E, ZURERA M, FERRERAS F. Application of Fisher linear discriminant analysis to speech/music classification [C]// International Conference on Computer as a Tool: EUROCON 2005. Washington, DC: IEEE Press, 2005: 21-24.
- [5] 卢坚, 陈毅松, 孙正兴, 等. 语音/音乐自动分类中的特征分析 [J]. 计算机辅助设计与图形学学报, 2003, 14(3): 233-237.
- [6] 胡艳芳, 吴及, 刘慧星. 基于 MLER 的语音/音乐分类方法 [J]. 清华大学学报, 2008, 48(s1): 720-724.
- [7] QURESHI A F, KIRANYAZ S, GABBOUJ M. A generic audio classification and segmentation approach for multimedia indexing and retrieval [J]. IEEE Transactions on Speech and Audio Processing, 2006, 9(3): 517-523.
- [8] 王欢良, 韩纪庆, 张磊. 基于支持向量机的变异语音分类 [J]. 哈尔滨工业大学学报, 2003, 35(4): 389-393.
- [9] 董婧, 赵晓晖, 应娜. 基于二进小波变换的基音检测算法 [J]. 吉林大学学报, 2006, 36(6): 978-981.
- [10] SARIKAYA R, PELLOM B L, HANSEN J H L. Wavelet packet transform features with application to speaker identification [C]// IEEE Nordic Signal Processing Symposium: NORSIG 98. Washington, DC: IEEE Press, 1998: 81-84.

(上接第 1418 页)

- [7] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326.
- [8] ZHAO HAI-TAO, SUN SHAO-YUAN, JING ZHONG-LIANG, et al. Local structure based supervised feature extraction [J]. Pattern Recognition, 2006, 39(8): 1546-1550.
- [9] DENG CAI, XIAOFEI HE, JIAWEI HAN, et al. Orthogonal laplacianfaces for face recognition [J]. IEEE Transactions on Image Processing, 2006, 15(11): 3608-3614.
- [10] ZHU LEI, ZHU SHAN-AN. Face recognition based on orthogonal discriminant locality preserving projections [J]. Neurocomputing,

2007, 70: 1543-1546.

- [11] 张志伟, 杨帆, 夏克文, 等. 一种有监督的 LPP 算法及其在人脸识别中的应用 [J]. 电子与信息学报, 2008, 30(3): 539-541.
- [12] 祝磊, 马莉, 厉力华. 一种基于 GDLPP 的人脸识别算法 [J]. 光电工程, 2008, 35(6): 108-112.
- [13] PHILLIPS P J, MOON H, RIZVI S A, et al. The feret evaluation methodology for face-recognition algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(10): 1090-1104.
- [14] PHILLIPS P J. The facial recognition technology (FERET) Database [EB/OL]. [2008-10-06]. [http://www.itl.nist.gov/iad/humanid/feret/feret\\_master.html](http://www.itl.nist.gov/iad/humanid/feret/feret_master.html).