

## 基于判别改进局部切空间排列特征融合的人脸识别方法

张强<sup>\*①</sup> 戚春<sup>②</sup> 蔡云泽<sup>①</sup>

<sup>①</sup>(上海交通大学电子信息与电气工程学院 上海 200240)

<sup>②</sup>(驻上海航天局中心军事代表处 上海 201109)

**摘要:**改进型局部切空间排列(ILTSA)是最近提出的一种流形学习方法。基于对ILTSA的线性逼近和判别拓展, 该文提出一种新的称为判别改进局部切空间排列(DILTSA)的特征提取方法, 并给出了理论证明和算法分析。基于最大邻域间隔准则和ILTSA, DILTSA能够同时保持类内与类间局部判别几何结构。此外, 提出一种增强型Gabor-like复数小波变换以缓解照明和表情变化对人脸识别的影响。通过融合Gabor-like复数小波变换和原始图像特征, 能够进一步提高人脸识别的准确率。在Yale和PIE人脸数据库上的实验结果证明了所提方法的有效性。

**关键词:**人脸识别; 流形学习; 线性逼近; 判别改进局部切空间排列; 增强型Gabor-like复数小波变换; 特征融合

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2012)10-2396-06

DOI: 10.3724/SP.J.1146.2011.01082

## Discriminant Improved Local Tangent Space Alignment Feature Fusion for Face Recognition

Zhang Qiang<sup>①</sup> Qi Chun<sup>②</sup> Cai Yun-ze<sup>①</sup>

<sup>①</sup>(School of Electronic, Information and Electrical Engineering, Shanghai Jiaotong University, Shanghai 200240, China)

<sup>②</sup>(Military Representative Office, Shanghai Aerospace Bureau Center, Shanghai 201109, China)

**Abstract:** Improved Local Tangent Space Alignment (ILTSA) is a recent manifold learning method. In this paper, based on linearization and discriminant extension of ILTSA, a novel feature extraction method named Discriminant ILTSA (DILTSA) is proposed with its theory and algorithm analysis. Based on maximum neighborhood margin criterion and ILTSA, DILTSA can preserve both local within-class and between-class geometry structures. In face recognition application, an augmented Gabor-like complex wavelet transform is proposed, which can efficiently alleviate the illumination and expression variation effect. An approach for face recognition based on the fusion of local and holistic features is developed. Experimental results on Yale and PIE face databases demonstrate the effectiveness of the proposed face recognition method.

**Key words:** Face recognition; Manifold learning; Linear extension; Discriminant Improved Local Tangent Space Alignment (DILTSA); Augmented Gabor-like complex wavelet transform; Feature fusion

### 1 引言

在实际应用中,许多高维数据是从内在低维流形抽样得到的。人们通常希望降维后的数据能够揭示和保持原始数据的内在几何结构。经典的线性降维方法,比如主成分分析(PCA)<sup>[1]</sup>和线性判别分析(LDA)<sup>[2]</sup>,不能揭示潜在的非线性流形结构或保持局部几何。最近,在流形学习领域提出了许多非线性降维技术。虽然这些方法对于人工和实际数据集能够产生好的结果,但是难于处理新样本。因此非线性

流形学习方法并不适用于人脸识别。为了获得明确的映射矩阵,一个自然的方式就是对非线性降维方法进行线性逼近,这方面已有的工作包括:邻域保持嵌入(NPE)<sup>[3]</sup>,局部保持映射(LPP)<sup>[4]</sup>和线性局部切空间排列(LLTSA)<sup>[5]</sup>等。旨在进一步提高识别性能,在人脸识别研究领域,最近提出了许多组合邻域保持几何属性和类别信息的判别式特征提取方法<sup>[6-8]</sup>。

在流形学习研究领域,Zhang等人<sup>[9]</sup>最近提出一种忠实逼近数据流形局部切空间的方法,并基于此提出了一种称为改进型局部切空间排列(ILTSA)的新型非线性降维方法。即使在数据稀疏或非均匀分布的情况下,ILTSA也能够有效地揭示数据流形的几何结构。然而,ILTSA本质上是一种流形学习方

2011-10-19收到,2012-06-18改回

国家自然科学基金(61004088)和上海市基础研究重点项目(09JC1408000)资助课题

\*通信作者:张强 zhangqiang741002@sina.com

法,存在难以处理新样本的缺点。本文提出对 ILTSA 进行线性逼近拓展。受已有的基于最大邻域间隔准则判别特征提取方法的启发,我们然后提出了一种称为判别改进局部切空间排列(DILTSA)的新型特征提取方法。在 DILTSA 方法中,分别采用不同的方法表征每个数据点的局部类间和局部类内几何结构,并采用简单有效的散度差形式目标准则。

Gabor-like 复数小波变换(GLWT)<sup>[10]</sup>是一种最近提出的多分辨率图像分析方法。作为一种对双树复小波变换(DT-CWT)的高效替代方法, GLWT 具有较好的时-频局部和多分辨率分析能力,有限数据冗余,计算高效,几乎平移不变,完全重构和线性相位的特点。这些优点使之特别适用于人脸识别特征提取。为补偿人脸图像照明变化的影响,我们提出对 GLWT 的高频子带图像进行对数变换和离散余弦变换(DCT)特征选择。此外,为了进一步提高人脸识别性能,提出了一种组合 GLWT 特征与原始图像像素特征的特征融合方法。

## 2 判别改进局部切空间排列(DILTSA)

### 2.1 改进型局部切空间排列(ILTSA)

ILTSA 算法由两步构成:局部切空间逼近和局部切坐标的全局排列。为了克服 PCA 切空间逼近在处理稀疏或者非均匀分布数据,或者数据流形具有大曲率时的不足, ILTSA 算法中的局部切空间逼近提出了两个改进。首先,  $\mathbf{x}_i$  点处的切空间原点固定为数据样本本身,而不是数据样本的均值;其次,最小化一个映射距离的加权和,这样就可以把较远邻域点的影响考虑进来。ILTSA 的算法流程如下:

步骤 1 邻域辨识:对于每个数据点  $\mathbf{x}_i$ , 假使  $\mathbf{X}_i = [\mathbf{x}_{i_1}, \mathbf{x}_{i_2}, \dots, \mathbf{x}_{i_k}] \in R^{n \times k}$  表示它的  $k$  个最近邻点(包括  $\mathbf{x}_i$  本身)组成的集合。应用最近邻(KNN)准则找到其  $k$  个最近邻点对应的索引。

步骤 2 计算  $\tilde{\mathbf{X}}_i$  和  $\mathbf{W}_i$ 。其中,  $\tilde{\mathbf{X}}_i = [\mathbf{x}_{i_1} - \mathbf{x}_i, \mathbf{x}_{i_2} - \mathbf{x}_i, \dots, \mathbf{x}_{i_k} - \mathbf{x}_i]$ ,  $\mathbf{W}_i$  为  $k \times k$  对角矩阵,  $\mathbf{W}_i(j, j) = w_{ij} = \exp(-\|\mathbf{x}_{i_j} - \mathbf{x}_i\|^2 / t)$  为新定义的权值。

步骤 3 计算  $(\tilde{\mathbf{X}}_i \mathbf{W}_i)^T (\tilde{\mathbf{X}}_i \mathbf{W}_i)$  的  $m$  个最大特征值对应的特征向量  $\mathbf{E}_i$ 。

步骤 4 计算

$$\mathbf{V}_i = \mathbf{I}_k - \mathbf{T}_i^+ \mathbf{T}_i \quad (1)$$

其中  $\mathbf{T}_i = \mathbf{B}_i^T \tilde{\mathbf{X}}_i = \mathbf{B}_i^T \tilde{\mathbf{X}}_i \mathbf{W}_i \mathbf{W}_i^{-1} = \mathbf{D}_i \mathbf{E}_i^T \mathbf{W}_i^{-1}$ 。上标“+”表示矩阵伪逆,上标“-1”表示矩阵求逆,这其中,假设  $\tilde{\mathbf{X}}_i \mathbf{W}_i$  的奇异值分解(SVD)为

$$\tilde{\mathbf{X}}_i \mathbf{W}_i = \mathbf{B}_i \mathbf{D}_i \mathbf{E}_i^T, \quad \mathbf{T}_i^+ = \mathbf{T}_i^T (\mathbf{T}_i \mathbf{T}_i^T)^{-1} \quad (2)$$

步骤 5 设置  $\mathbf{C}_i = \mathbf{V}_i \mathbf{V}_i^T$  并且采用如式(3), 式(4)更新  $\mathbf{C}$ :

$$\mathbf{C}(\mathbf{I}_i, \mathbf{I}_i) := \mathbf{C}(\mathbf{I}_i, \mathbf{I}_i) + \mathbf{C}_i, \quad \mathbf{C}(\mathbf{I}_i, i) := \mathbf{C}(\mathbf{I}_i, i) - \mathbf{C}_i \mathbf{e}_k \quad (3)$$

$$\mathbf{C}(i, \mathbf{I}_i) := \mathbf{C}(i, \mathbf{I}_i) - \mathbf{e}_k^T \mathbf{C}_i, \quad \mathbf{C}(i, i) := \mathbf{C}(i, i) + \mathbf{e}_k^T \mathbf{C}_i \mathbf{e}_k \quad (4)$$

其中  $\mathbf{C}(\mathbf{I}_i, \mathbf{I}_i)$  是  $\mathbf{C}$  中的子矩阵, 它的第  $(j, k)$  项是  $\mathbf{C}(\mathbf{I}_i(j), \mathbf{I}_i(k))$ ,  $\mathbf{C}(\mathbf{I}_i, i)$  是一列向量, 它的第  $j$  项是  $\mathbf{C}(\mathbf{I}_i(j), i)$ ,  $\mathbf{C}(i, \mathbf{I}_i)$  是一行向量, 它的第  $j$  项是  $\mathbf{C}(i, \mathbf{I}_i(j))$ 。  $\mathbf{C}(i, i)$  是  $\mathbf{C}$  的第  $i$  个对角元素。

步骤 6 最后嵌入  $\mathbf{Y}$  的各行由  $\mathbf{C}$  对应从第 2 到第  $(m+1)$  个最小的特征值所对应的特征向量给出。

### 2.2 本文提出的目标函数和算法分析

由于只能对训练样本进行降维,原有的 ILTSA 算法不适用于人脸识别。为克服这一缺点,我们加入从  $\mathbf{X}$  到  $\mathbf{Y}$  的明确的线性映射,也就是  $\mathbf{Y} = \mathbf{V}^T \mathbf{X}$ 。这样原有 ILTSA 的目标函数可以转换为式(5)的形式:

$$\left. \begin{aligned} J_1(\mathbf{Y}) &= \min \operatorname{tr}(\mathbf{Y} \mathbf{C} \mathbf{Y}^T) = \min \operatorname{tr}(\mathbf{V}^T \mathbf{X} \mathbf{C} \mathbf{X}^T \mathbf{V}) \\ \text{s.t. } \mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V} &= \mathbf{I} \end{aligned} \right\} (5)$$

我们称该算法为线性改进局部切空间排列(LILTSA)。LILTSA 仅仅专注于保持数据点的局部几何结构,而忽略了标签信息。为了增强 LILTSA 的判别能力,我们提出一种判别改进局部切空间排列(DILTSA)算法。

2.2.1 局部类内几何结构保持 为了保持样本的类内局部几何结构,定义同类样本之间的相似性权值为

$$\mathbf{W}_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / t), & \text{类标签 } l_i = l_j \\ 0, & \text{其它} \end{cases} \quad (6)$$

类内局部保持目标函数定义为

$$\begin{aligned} \min_{\mathbf{Y}} \sum_{ij} \|\mathbf{y}_i - \mathbf{y}_j\|^2 \mathbf{W}_{ij} \\ &= \operatorname{tr} \left( \sum_{ij} (\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_j) (\mathbf{V}^T \mathbf{x}_i - \mathbf{V}^T \mathbf{x}_j)^T \mathbf{W}_{ij} \right) \\ &= \operatorname{tr} \left( \sum_i \mathbf{V}^T \mathbf{x}_i \mathbf{D}_{ii}^{(w)} \mathbf{x}_i^T \mathbf{V} - \sum_{ij} \mathbf{V}^T \mathbf{x}_i \mathbf{W}_{ij} \mathbf{x}_j^T \mathbf{V} \right) \\ &\propto \operatorname{tr}(\mathbf{V}^T \mathbf{X} \mathbf{L}_w \mathbf{X}^T \mathbf{V}) \end{aligned} \quad (7)$$

其中  $\mathbf{L}_w = \mathbf{D}_w - \mathbf{W}$  为拉普拉斯矩阵,  $\mathbf{D}_w$  为对角项为  $\mathbf{W}$  行或列之和的对角矩阵,  $\mathbf{D}_{ii}^{(w)} = \sum_j \mathbf{W}_{ij}$ 。

$\mathbf{X} \mathbf{L}_w \mathbf{X}^T$  称为局部类内散度矩阵。

2.2.2 局部类间切空间排列 对于分类问题,仅仅保持局部类内几何通常不能保证获得好的分类结果。因此,本文提出采用局部类间切空间排列来表征局部类间分离。对于每个样本  $\mathbf{x}_i$ , 表示与它不同类的  $k_b$  个最近类样本为矩阵  $\mathbf{X}_{b,i} = [\mathbf{x}_{b,i1}, \mathbf{x}_{b,i2}, \dots, \mathbf{x}_{b,ik_b}]$  (其中,  $\mathbf{x}_i$  本身看作它的第 1 个最近邻,  $\mathbf{x}_{b,i1} = \mathbf{x}_i$ )。为了最大化局部类间可分离性,所推荐算法的另一个

目标函数是最大化局部类间重构误差之和  $E_{b,i}$  :

$$\begin{aligned} \max_Y \sum_i \|E_{b,i}\|^2 &= \max_Y \text{tr}(Y C_b Y^T) \\ &= \max_V \text{tr}(V^T X C_b X^T V) \end{aligned} \quad (8)$$

其中矩阵  $C_b$  的计算如 2.1 节所述, 不同之处是最近邻样本选自不同类(样本本身除外)。  $X C_b X^T$  称作局部类间切空间排列散度矩阵。

**2.2.3 目标函数与算法分析** 为达到分类目的, 我们想要找到一个映射使得降维后, 类内样本尽量彼此靠近并且类间样本彼此远离。受最大间隔准则启发, 本文提出一个改进的最大邻域间隔准则。最大间隔准则保持了全局几何结构但忽略了实际中潜在的人脸流形。通过邻域保持, 寻求能够保持局部几何结构的映射。具体地, 我们提出最大化以下的目标函数:

$$\begin{aligned} J_L &= \text{tr}(V^T X C_b X^T V - \alpha V^T X L_w X^T V) \\ &= \text{tr}(V^T X (C_b - \alpha L_w) X^T V) \end{aligned} \quad (9)$$

其中  $\alpha$  是一个可调整的参数。

注意到矩阵  $X(C_b - \alpha L_w)X^T$  是对称的, 最优映射向量  $v_1, v_2, \dots, v_d$  为对应于  $d$  个最大特征值  $\lambda_1, \lambda_2, \dots, \lambda_d$  的特征向量, 也就是

$$(X(C_b - \alpha L_w)X^T)v_j = \lambda_j v_j \quad (10)$$

其中  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ 。

假使  $\alpha > 0$  并且  $v$  是  $X C_b X^T - \alpha X L_w X^T$  对应于特征值  $\lambda > 0$  的特征向量, 我们有下面定理 1 中阐述的结论。

**定理 1** 当  $\alpha$  趋于  $+\infty$  时,  $v$  位于  $X L_w X^T$  的零空间并且对应于正特征值  $\lambda$  的特征向量包含最具判别力的信息。

**证明** 由假设, 有

$$(X C_b X^T - \alpha X L_w X^T)v = \lambda v \quad (11)$$

式(11)可变形为

$$v^T X L_w X^T v = \frac{1}{\alpha}(v^T X C_b X^T v - \lambda) \quad (12)$$

注意到  $\lambda > 0$ , 有式(13)成立:

$$v^T X L_w X^T v < \frac{1}{\alpha} v^T X C_b X^T v \quad (13)$$

因为  $X L_w X^T$  与  $X C_b X^T$  都是半正定矩阵, 因此有

$$v^T X L_w X^T v \geq 0, \quad v^T X C_b X^T v \geq 0 \quad (14)$$

组合式(13)和式(14), 得到结论:

$$\lim_{\alpha \rightarrow \infty} v^T X L_w X^T v = 0 \quad (15)$$

因此, 我们有  $\lim_{\alpha \rightarrow \infty} X L_w X^T v = 0$ 。

由式(11), 可以得到

$$v^T X C_b X^T v = \alpha v^T X L_w X^T v + \lambda \quad (16)$$

注意到  $v^T X L_w X^T v \geq 0, \lambda > 0$  和  $\alpha > 0$ , 于是有

$$v^T X C_b X^T v > 0, \quad \frac{v^T X C_b X^T v}{v^T X L_w X^T v} \rightarrow +\infty \quad \text{证毕}$$

如果目标函数采用类间与类内局部散度比值的形式, 为避免小样本尺寸问题, 通常采用 PCA 预降维使得类内散度矩阵非奇异, 然而这样做的结果是会损失一部分有用的判别信息; 另外如果直接在类内散度矩阵的零空间中寻求最优判别特征, 由于类内散度矩阵的高维, 决定类内散度矩阵零空间的计算复杂。本文采用散度差形式的目标函数, 不需要进行矩阵求逆, 直接避免了小样本尺寸问题, 在人脸识别应用中, 样本数据的维数  $n$  通常非常大, 直接求解大小为  $n \times n$  的矩阵  $X(C_b - \alpha L_w)X^T$  计算量太大。为了减小计算复杂性, 可以证明利用 PCA 移除总散度矩阵  $S_i$  的零空间, 不会损失判别信息。

### 2.3 DILTSA 算法步骤

本文所提 DILTSA 特征提取方法的算法步骤如下:

(1) 利用 PCA, 计算  $S_i$  对应全部正特征值的特征向量组成的矩阵  $P$ , 并将所有训练样本映射到  $S_i$  的列空间, 也就是,  $Z = P^T X$ 。

(2) 对于每个数据点  $z_i$ , 按照式(6)和式(7)构造局部类内散度矩阵  $Z L_w Z^T$ 。

(3) 对于每个数据点  $z_i$ , 决定它的  $k_b$  个不同类最近点。构造排列矩阵  $C_b$ 。

(4) 求解特征值问题:

$$Z(C_b - \alpha L_w)Z^T u = \lambda u \quad (17)$$

(5) 假设  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$  为  $Z(C_b - \alpha L_w)Z^T$  的  $d$  个最大特征值, 并且它们对应的特征向量为  $u_1, u_2, \dots, u_d$ 。最优映射矩阵可以表示为  $V = P U$ , 其中  $U = [u_1, u_2, \dots, u_d]$ 。

## 3 特征融合

Chaudhury 等人<sup>[10]</sup>辨识了一族渐进收敛到 Gabor-like 函数的解析样条小波。特别地, 他们构造了一族有向复数小波。对于充分大的阶数, 这族有向复数小波类似于有向 Gabor 函数。本文取图像变换分解层数为 3。图 1 给出了对取自 Yale 库<sup>[1]</sup>的一幅人脸图像进行 Gabor-like 变换, 所得到的 3 层 6 个方向的高频子带幅值响应图像。

在提出的增强型 Gabor-like 变换方法中, 我们对每幅高频子带图像进行对数变换。由于对数变换能够压缩较亮的像素值并且能拓宽较暗的像素值, 结果是能够部分减轻照明条件对人脸识别的影响。如图 2 所示给出 Yale 人脸数据库的一幅人脸图像和它的第 1 层分解系数图像, 同时给出了应用对数




图 1 Yale 人脸图像和它的幅值响应图像



图 2 Yale 人脸图像子带图像对数变换增强

变换后的结果。可以看到应用对数变换后能够增强子带图像的对比度,并缓解照明变化的影响。

为进一步提取更具判别性的特征,在对子带图像进行对数变换后,又对变换后的子带图像进行了离散余弦变换(DCT)处理。DCT 系数一般分为低频,中频和高频 3 部分。低频相关于照明条件而高频相关于噪音,本文选择中频 DCT 系数。

对于每幅人脸图像  $I$ ,通过 6 个方向和 3 层图像变换后,把对应第  $i$  个方向和第  $j$  层的子带图像按列连成一个长向量  $G_{ij}$ 。最后,图像  $I$  变换后的特征向量可以表示为一个长向量:

$$G = [G_{1,1}, G_{2,1}, \dots, G_{6,1}, G_{1,2}, \dots, G_{6,2}, G_{1,3}, \dots, G_{6,3}]^T \quad (18)$$

既然在 DILTSA 算法实现中,可以采用 PCA 预处理而不损失任何判别信息,这样对输入样本的维数大小要求不高。为进一步提高人脸识别的准确率,我们提出一种新颖的基于 DILTSA 的特征融合方法。具体地说,首先以抽样因子 2 下抽样原始图像,然后把它同式(18)得到的频域图像特征连接成一个长向量。这样做的出发点是希望充分利用二者的互补性。下面给出具体的融合步骤:

步骤 1 输入训练人脸图像集  $I = \{I_1, I_2, \dots, I_N\}$ ,提取增强型 Gabor-like 人脸特征。对于每一训练图像,连接处理后的子带图像向量成一长的向量  $x_1 \in R^{n_1}$ 。

步骤 2 下抽样每个原始的人脸图像并连接成一向量  $x_2 \in R^{n_2}$ 。

步骤 3 对于每一图像,连接其频域特征向量  $x_1$  和原始特征向量  $x_2$  为一新的长向量  $x_f \in R^{n_1+n_2}$  如下:

$$x_f = (x_1/\sigma_1, x_2/\sigma_2)^T \quad (19)$$

其中  $\sigma_1, \sigma_2$  分别是  $x_1$  和  $x_2$  的标准差。

步骤 4 应用 DILTSA 算法提取判别特征。

## 4 实验结果与讨论

本节通过实验验证本文所提人脸识别方法的有效性。实验在两个流行的人脸数据库 Yale<sup>[1]</sup>和 PIE<sup>[11]</sup>上进行。所比较的其它方法包括 Eigenface<sup>[1]</sup>, fisherface<sup>[2]</sup>, ONPDA<sup>[6]</sup>, DLPP/MMC<sup>[7]</sup>, TSDA<sup>[8]</sup>和 MMC<sup>[12]</sup>等。

### 4.1 在 Yale 数据库上的实验结果

Yale 人脸数据库包括 15 个人的 165 张图像,每人 11 张。图像变化包括照明条件(左侧光,中心光和右侧光)、人脸表情变化(标准,高兴,打盹,惊讶和眨眼),佩戴或者不佩戴眼镜。图 3 给出裁剪好的两个人的全部图像。分别从每人的 11 张图片中随机抽取 2, 3, 4, 5 张作为训练样本集,剩下的图像作为测试集。对于每种样本划分,进行 50 次迭代训练,取其平均值作为正确识别率,表 1 为所比较的方法及其识别率,(标准差,取得最佳结果时所保留的特征维数)。从实验结果可以看出,对 ILTSA 的直接线性逼近不能取得理想的人脸识别结果,原因是其没有利用样本的类别信息。而利用类别标签信息的方法(包括提出的 DILTSA)能够取得比非监督方法(包括 Eigenface 和 LILTSA)更好的识别结果。同时利用类别信息和图像数据局部邻域信息的方法能够获得相接近的识别准确率。而本文提出的方法由于考虑了数据流形的非线性结构,并且 PCA 预降维不存在判别信息的损失,能够在大多数情况下取得比其它类似方法更好的准确率。从表中可以看出,本文所提出的结合 Gabor-like 小波和 DILTSA 的方法能够进一步提高正确识别率,而且提高幅度比较大。从表中我们还可以看出,融合频域和空域的特征表达确实能够进一步提高识别准确率。



图3 Yale 人脸数据库样本人脸图像

表1 在 Yale 数据库上的实验结果

方法	2 个训练样本	3 个训练样本	4 个训练样本	5 个训练样本
特征脸(Eigenface)	46.33(3.41,29)	51.71(2.01,44)	54.05(3.74,59)	58.17(3.39,74)
费舍尔脸(Fisherface)	47.82(6.51,14)	60.71(5.72,14)	68.97(3.33,14)	73.82(3.57,14)
TSDA	53.41(5.73,14)	64.47(4.54,14)	73.23(5.50,15)	75.17(3.44,16)
MMC	51.48(5.13,14)	60.75(3.87,14)	67.37(4.73,16)	71.56(4.45,16)
LILTSA	40.79(3.67,17)	44.72(4.16,17)	49.41(3.68,17)	51.42(4.19,15)
ONPDA	43.44(4.64,14)	60.33(4.99,13)	70.19(2.45,15)	76.67(3.82,14)
DLPP/MMC	53.06(4.37,14)	65.48(3.57,14)	73.26(3.71,15)	77.04(3.80,15)
DILTSA	53.91(4.75,15)	66.02(4.21,14)	74.08(3.73,14)	78.29(3.12,15)
AGLWT+DILTSA	61.02(5.07,14)	76.23(4.61,14)	84.88(3.34,15)	88.93(2.52,14)
特征融合	68.09(3.98,14)	81.52(2.86,14)	87.77(3.30,14)	91.51(2.82,14)

当每类取 5 个训练样本时, 图 4 中给出了识别率与约简维数的关系曲线。从图中可以看出, 所提出的 DILTSA 识别结果对维数变化不很敏感, 能够取得比其它方法更加稳定的识别结果。所提出的特征融合方法能够显著提高识别性能。

#### 4.2 在 PIE 数据库上的实验结果

CMU PIE 人脸数据库包含 68 个人, 总共 41368 张人脸图像。人脸图像包括姿态, 照明和表情变化。在实验当中, 以双眼位置为基准把原始图像对齐, 裁剪, 并把它们缩放到  $32 \times 32$  尺寸大小。从数据库中, 我们选择其中 5 个近似正面的姿态图像(C05, C07, C09, C27, C29) 并应用其中 20 个人的 800 张图像用于实验。图 5 给出了对应一个人的

人脸图像。

分别从每人的 40 张图片中随机抽取 5, 10, 15, 20 张作为训练样本集, 剩下的图像作为测试集。对于每种样本划分, 进行 20 次迭代训练, 取其平均值作为正确识别率, 表 2 为所比较的方法及其识别率(标准差, 取得最佳结果时所保留的特征维数)。同对表 1 中结果的分析类似, 从表 2 可以看出, 在具有较大照明变化的 PIE 数据库上, 在几个典型的基于结合判别和局部信息的方法中, 本文所提出的 DILTSA 方法取得了更好的识别性能。结合 Gabor-like 小波和 DILTSA 的方法能够进一步提高正确识别率。从表中还可以看出, 融合频域和空域的特征表达确实能够进一步提高识别准确率。当每类取 5 个训练样本时, 在图 6 中给出了识别率与约简维数的关系曲线。从曲线变化可以看出, 随着维数提高所提出的方法识别率逐步提高, 最后达到稳定。

## 5 结束语

基于对 ILTSA 线性逼近和判别式拓展, 本文提出一种新颖的称为判别改进局部切空间排列(DILTSA)的特征提取方法。另外提出了一种基于 DILTSA 的新型特征融合方法。人脸识别实验结果验证了我们的算法设计和理论分析是合理的。将来的工作包括在其它复杂人脸数据库上的算法验证, 以及在其它生物特征识别中的应用。

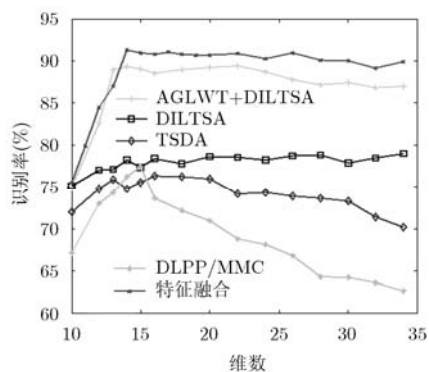


图4 Yale 数据库上识别率与维数的关系曲线



图 5 PIE 人脸数据库样本人脸图像

表 2 在 PIE 人脸数据库上的实验结果

方法	5 个训练样本	10 个训练样本	15 个训练样本	20 个训练样本
特征脸(Eigenface)	37.05(2.13,90)	53.27(2.15,180)	64.65(2.42,270)	73.17(2.13,360)
费舍尔脸(Fisherface)	68.61(2.54,19)	80.98(2.21,19)	85.74(1.69,19)	87.55(1.62,19)
TSDA	70.68(2.99,19)	81.83(2.11,19)	85.97(1.75,20)	87.65(2.26,20)
MMC	62.04(2.49,25)	80.77(2.91,19)	87.82(1.56,20)	90.85(1.93,19)
LILTSA	33.41(2.14,39)	45.89(1.81,41)	56.92(2.29,41)	66.15(2.67,40)
ONPDA	66.73(2.31,30)	79.90(2.56,32)	85.06(1.68,28)	88.04(2.37,30)
DLPP/MMC	70.21(3.05,21)	81.03(2.41,20)	85.78(1.93,19)	87.61(1.64,19)
DILTSA	73.47(2.71,21)	85.82(2.32,20)	89.52(1.95,19)	92.65(1.34,20)
AGLWT+DILTSA	78.38(2.59,22)	91.61(1.61,19)	96.41(1.05,21)	97.88(0.68,20)
特征融合	81.26(2.65,20)	93.96(1.82,21)	97.48(1.10,20)	98.76(0.64,20)

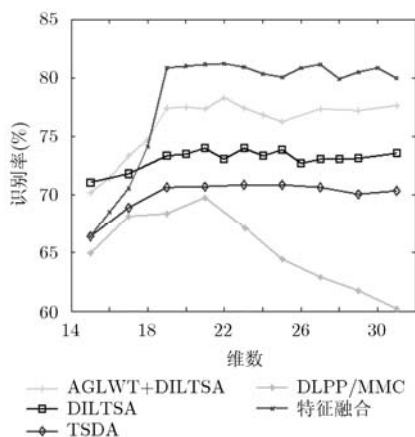


图 6 PIE 数据库上识别率与维数的关系曲线

### 参 考 文 献

[1] Turk M A and Pentland A P. Face recognition using eigenfaces [C]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Maui, Hawaii, USA, 1991: 586-591.

[2] Belhumeur P N, Hespanha J P, and 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.

[3] He X, Cai D, Yan S, et al. Neighborhood preserving embedding[C]. Proceedings of the 10th IEEE International Conference on Computer Vision, Beijing, 2005: 1208-1213.

[4] 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.

[5] Zhang T, Yang J, Zhao D, et al. Linear local tangent space alignment and application to face recognition[J]. *Neurocomputing*, 2007, 70(7-9): 1547-1553.

[6] Hu H F. Orthogonal neighborhood preserving discriminant analysis for face recognition [J]. *Pattern Recognition*, 2008, 41(6): 2045-2054.

[7] Lu G F, Lin Z, and Jin Z. Face recognition using discriminant locality preserving projections based on maximum margin criterion [J]. *Pattern Recognition*, 2010, 43(10): 3572-3579.

[8] Lai Z, Jin Z, and Wong W K. Tangent space discriminant analysis for feature extraction[C]. Proceedings of 2010 IEEE 17th International Conference on Image Processing, Hong Kong, 2010: 3793-3796.

[9] Zhang P, Qiao H, and Zhang B. An improved local tangent space alignment method for manifold learning [J]. *Pattern Recognition Letters*, 2011, 32(2): 181-189.

[10] Chaudhury K N and Unser M. Construction of Hilbert transform pairs of wavelet bases and Gabor-like transforms [J]. *IEEE Transactions on Signal Processing*, 2009, 57(9): 3411-3425.

[11] Sim T, Baker S, and Bsat M. The CMU pose, illumination, and expression database [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, 25(12): 1615-1618.

[12] Li H F, Jiang T, and Zhang K. Efficient and robust feature extraction by maximum margin criterion[J]. *IEEE Transactions on Neural Networks*, 2006, 17(1): 157-165.

张 强： 男，1974 年生，博士生，研究方向为机器学习、模式识别、图像处理。

戚 春： 男，1974 年生，硕士，研究方向为模式识别、目标识别。

蔡云泽： 女，1975 年生，副教授，研究方向为鲁棒控制、鲁棒滤波、小波去噪。