

# 快速核 Foley-Sammon 鉴别分析及其在人脸识别上的应用

范 燕<sup>1</sup> 宋晓宁<sup>1</sup> 吴小俊<sup>2</sup> 杨静宇<sup>3</sup>

(江苏科技大学电子信息学院 镇江 212003)<sup>1</sup> (江南大学信息工程学院 无锡 214112)<sup>2</sup>

(南京理工大学计算机科学与技术系 南京 210094)<sup>3</sup>

**摘 要** 核 Foley-Sammon 鉴别分析由于可以抽取得到原始样本的非线性正交特征,因此被广泛应用于模式识别的研究领域。但是该算法在具体求解每一个特征向量过程中均需求解相应的广义特征方程,因此非常耗时。为了克服这一困难,提出了一种新的快速近似算法即核 Foley-Sammon 鉴别分析,有效地避免了多次求解广义特征方程。在 ORL 人脸数据库上的实验结果表明,该算法不仅在识别性能上优于核线性鉴别分析,而且在特征抽取速度上优于传统的核 Foley-Sammon 鉴别分析。

**关键词** 核 Foley-Sammon 鉴别分析,特征抽取,人脸识别

中图分类号 TP391.4 文献标识码 A

## Fast Kernel Foley-Sammon Discriminant Analysis with Application to Face Recognition

FAN Yan<sup>1</sup> SONG Xiao-ning<sup>1</sup> WU Xiao-jun<sup>2</sup> YANG Jing-yu<sup>3</sup>

(School of Electronic and Information, Jiangsu University of Science and Technology, Zhenjiang 212003, China)<sup>1</sup>

(School of Information Engineering, Jiangnan University, Wuxi 214122, China)<sup>2</sup>

(Department of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing 210094, China)<sup>3</sup>

**Abstract** Kernel Foley-Sammon Discriminant Analysis (KFSDA) is extensively applied on the field of pattern recognition with the capacity of extracting nonlinear orthonormal features from original samples. But each eigenvector should be achieved by calculating the corresponding generalized eigenfunction with this algorithm, and it is very time-consuming. In order to overcome this problem, a fast algorithm of KFSDA named Fast Kernel Foley-Sammon Discriminant Analysis (FKFSDA) was proposed. Experimental results on the ORL face database demonstrate the proposed algorithm not only outperforms Kernel Linear Discriminant Analysis (KLDA) in recognition rates, but also outperforms conventional Foley-Sammon Discriminant Analysis in feature extraction speed.

**Keywords** Kernel Foley-Sammon discriminant analysis, Feature extraction, Face recognition

## 1 引言

基于 Fisher 准则<sup>[1-3]</sup>的线性鉴别已被公认为特征抽取的有效方法之一,其基本思想是选择使得 Fisher 准则函数达到极值的向量作为最佳鉴别向量,当样本在该向量上投影后,同时达到最大的类间离散度和最小的类内离散度。在 Fisher 思想的基础上,Wilks<sup>[2]</sup>等创立了经典的 Fisher 线性鉴别分析,近年来,Belhumeur<sup>[3]</sup>等用来解决人脸识别问题。此外, Foley 和 Sammon 在 1975 年提出了 Foley-Sammon 线性鉴别分析<sup>[4]</sup> (Foley-Sammon Linear Discriminant Analysis, FSLDA)。FSLDA 的基本思想是采用一组最大化 Fisher 准则函数且满足正交条件的最佳鉴别向量集进行特征抽取。由于满足正交条件的最佳鉴别向量在几何上是独立的,因此可明显地降低用该最佳鉴别向量集抽取得到的特征之间的冗余信息。然而 FSLDA 的框架仍旧是基于线性变化的特征提取方

法,因此最终抽取得到的仍然是线性特征。但是,现实中许多问题都是非线性可分的。例如在人脸识别问题中,由于光照、姿态、表情等不同而引起的人脸图像差异所造成的人脸图像分布往往是非线性的和复杂的<sup>[5]</sup>,所以上述 FSLDA 方法在完成人脸等图像识别任务时不能取得令人满意的结果。为了解决非线性问题的特征提取问题,有学者采用核技术<sup>[6-11]</sup>将 FSLDA 方法推广到高维空间,得出了核 Foley-Sammon 鉴别分析<sup>[12,13]</sup> (Kernel Foley-Sammon Discriminant Analysis, KFSDA)方法。但是无论是 FSLDA 方法还是 KFSDA 方法,在求解得到前  $r$  个特征向量之后,再求解第  $r+1$  个特征向量时,均需求解一个相应的广义特征方程,因此计算的复杂度和时耗较高。为了克服这一困难,本文针对人脸识别问题,采用 KFSDA 提出了一种取得非线性正交 Fisher 特征向量的新方法——快速核 Foley-Sammon 鉴别分析 (Fast Kernel Foley-Sammon Discriminant Analysis, FKFSDA),有效地降低了计

到稿日期:2008-07-08 返修日期:2008-10-17 本文受国家自然科学基金(60572034),江苏省自然科学基金(BK2004058),江苏科技大学青年教师科研立项资助。

范 燕(1978—),女,硕士,讲师,主要研究方向为模式识别、图像处理等, E-mail: ecsi\_fy@yahoo.com.cn; 宋晓宁(1975—),男,博士研究生,讲师,主要研究方向为模式识别、图像处理等; 吴小俊(1967—),男,教授,博士生导师,研究方向为模式识别、计算机视觉等; 杨静宇(1941—),男,教授,博士生导师,研究方向为模式识别、计算机视觉、图像处理等。

算特征向量的时间复杂度,在人脸数据库上的实验结果也验证了该算法的有效性。

## 2 相关算法分析和实现

### 2.1 Foley-Sammon 线性鉴别分析

设  $\omega_1, \omega_2, \dots, \omega_C$  为  $C$  个样本类,原始样本  $X$  为  $n$  维实向量,即  $X \in R^n$ ,则相应的类内散布矩阵  $S_w$ 、类间散布矩阵  $S_b$  和总体散布矩阵  $S_t$  分别为

$$S_w = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} (X_j^i - m_i)(X_j^i - m_i)^T \quad (1)$$

$$S_b = \sum_{i=1}^C \frac{N_i}{N} (m_i - m_0)(m_i - m_0)^T \quad (2)$$

$$S_t = \frac{1}{N} \sum_{j=1}^N (X_j - m_0)(X_j - m_0)^T = S_w + S_b \quad (3)$$

其中,  $N_i$  为第  $i$  类训练样本的数目,  $N$  为训练样本的总数,  $X_j^i$  ( $i=1, \dots, C; j=1, \dots, N_i$ ) 表示第  $i$  类中第  $j$  个训练样本,  $X_j$  ( $j=1, \dots, N$ ) 表示第  $j$  个训练样本,  $m_i = E\{X | X \in \omega_i\}$  为第  $i$  类训练样本的均值,  $m_0 = \sum_{i=1}^C \frac{N_i}{N} m_i$  为全体训练样本的均值。

则 Fisher 鉴别准则函数定义为

$$J(W) = \frac{W^T S_b W}{W^T S_w W} \quad (4)$$

特别地,当  $S_w$  非奇异时, Fisher 准则等价<sup>[14]</sup>如下:

$$J(W) = \frac{W^T S_b W}{W^T S_t W} \quad (5)$$

假设  $w_1, \dots, w_d$  是通过 Fisher 鉴别准则得到的 FSLDA 最佳鉴别矢量集,则  $w_1, \dots, w_d$  按如下方式产生:  $w_1$  是第一个 Fisher 鉴别矢量,即

$$w_1 = \arg \max_W J(W) \quad (6)$$

同时,假设我们已经得到前  $r$  个 FS 最佳鉴别矢量  $w_1, \dots, w_r$ ,则第  $r+1$  个 FS 最佳鉴别矢量  $w_{r+1}$  满足条件

$$w_{r+1}^T w_i = 0, i=1, 2, \dots, r \quad (7)$$

下使得  $J(W)$  为最大的鉴别函数。

事实上,FS 最佳鉴别矢量集的第一个矢量就是 Fisher 最佳鉴别矢量,即广义特征方程  $S_b W = \lambda S_w W$  的最大特征值所对应的单位特征矢量  $w_1$ 。在求出 FS 最佳鉴别矢量集的前  $r$  个鉴别矢量  $w_1, \dots, w_r$  之后,第  $r+1$  个 FS 最佳鉴别矢量  $w_{r+1}$  可以由求解下列优化问题得到:

$$\begin{cases} \max(J(W)) \\ w_j^T w_{r+1} = 0, j=1, 2, \dots, r \\ w_{r+1} \in R^n \end{cases} \quad (8)$$

此优化问题可以通过相应地求解特征方程的形式得到解决,因此我们可得到以下的定理。

**定理 1** 当矩阵  $S_t$  可逆时,FS 最佳鉴别矢量集的第一个鉴别矢量  $w_1$  取为单位化的 Fisher 最优鉴别矢量;当取得前  $r$  个最优鉴别矢量  $w_1, \dots, w_r$  之后,第  $r+1$  个鉴别矢量  $w_{r+1}$  为下列广义特征方程的最大特征值  $\lambda_{\max}$  所对应的单位特征向量,且满足  $J(w_{r+1}) = \lambda_{\max}$ :

$$B_r S_b W = \lambda S_t W \quad (9)$$

其中

$$\begin{aligned} B_r &= I_n - D_r^T (D_r S_t^{-1} D_r^T)^{-1} D_r S_t^{-1} \\ D_r &= (w_1, w_2, \dots, w_r)^T \end{aligned} \quad (10)$$

因此根据 FSLDA 的定义,我们可以得出:

(1) FSLDA 方法是一种正交变换;

(2) 在所有的正交变换中, FSLDA 方法在 Fisher 判别准则意义上是最佳的。

### 2.2 核 Foley-Sammon 鉴别分析

FSLDA 方法由于只能得到数据的线性特征,所以无法对非线性特征进行有效的特征提取,因此有学者采用核技术得出了基于核函数的 KFSDA 方法。基于核函数的 Foley-Sammon 鉴别分析<sup>[12,13]</sup>基本思想是:首先将原始训练样本通过一个非线性映射  $\Phi$  变换到某一高维(可能是无限维)特征空间  $H$  中,然后在此高维特征空间  $H$  中完成 FSLDA。由于特征空间  $H$  的维数非常高甚至可能是无穷维,为了避免直接显式地处理变换后的样本,因此在实现过程中引入了核函数<sup>[6]</sup>,即著名的核方法(kernel trick)。

设经过非线性映射  $\Phi$  后所对应的样本矢量为  $\Phi(X) \in H$ ,那么高维特征空间  $H$  中训练样本的类内散布矩阵  $S_w^\Phi$ 、类间散布矩阵  $S_b^\Phi$  和总体散布矩阵  $S_t^\Phi$  分别为:

$$S_w^\Phi = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^{N_i} (\Phi(X_j^i) - m_i^\Phi)(\Phi(X_j^i) - m_i^\Phi)^T \quad (11)$$

$$S_b^\Phi = \sum_{i=1}^C \frac{N_i}{N} (m_i^\Phi - m_0^\Phi)(m_i^\Phi - m_0^\Phi)^T \quad (12)$$

$$S_t^\Phi = \frac{1}{N} \sum_{j=1}^N (\Phi(X_j) - m_0^\Phi)(\Phi(X_j) - m_0^\Phi)^T \quad (13)$$

其中,  $N_i$  和  $N$  定义同 FSLDA,  $\Phi(X_j^i)$  ( $i=1, \dots, C; j=1, \dots, N_i$ ) 表示高维特征空间  $H$  中第  $i$  类的第  $j$  个训练样本,  $\Phi(X_j)$  ( $j=1, \dots, N$ ) 表示高维特征空间  $H$  中第  $j$  个训练样本,  $m_i^\Phi = E\{\Phi(X) | \Phi(X) \in \omega_i\}$  为高维特征空间  $H$  中第  $i$  类训练样本的均值,  $m_0^\Phi = \sum_{i=1}^C \frac{N_i}{N} m_i^\Phi$  为高维特征空间  $H$  中全体训练样本的均值。

因此,高维特征空间  $H$  中广义 Fisher 鉴别准则函数可定义为:

$$J(\bar{W}) = \frac{\sum_{i=1}^d w_i^T S_b^\Phi w_i}{\sum_{i=1}^d w_i^T S_t^\Phi w_i} \quad (14)$$

其中,  $\bar{W} = (w_1, w_2, \dots, w_d)$  表示在高维特征空间  $H$  中的特征矢量集。

在高维特征空间  $H$  中, KFSDA 可定义为:寻找一组广义最佳鉴别矢量  $w_1, \dots, w_d$ , 它们在最大化广义 Fisher 鉴别准则函数式(14)的同时满足以下正交条件,即

$$w_i^T w_j = 0, \forall i \neq j, i, j=1, \dots, d \quad (15)$$

但是,我们知道特征空间  $H$  的维数非常高甚至是无穷维的,直接显式地计算求解一组广义最佳鉴别矢量集  $w_1, \dots, w_d$  是不可能的,因此必须对式(14)、(15)进行变换,使它们只包含映射后样本的内积运算,这样就可以利用核方法进行有效的计算。根据再生核理论,任何一个解矢量  $W$  一定位于由特征空间  $H$  中所有的训练样本  $\Phi(X_1), \dots, \Phi(X_N)$  所张成的空间,因此我们有

$$W = \sum_{i=1}^N \alpha^i \Phi(X_i) = \Phi \alpha \quad (16)$$

其中,

$$\begin{aligned} \Phi &= (\Phi(X_1), \dots, \Phi(X_N)) \\ \alpha &= (\alpha^1, \dots, \alpha^N)^T \in R^N \end{aligned} \quad (17)$$

把特征空间  $H$  中的样本  $\Phi(X_i)$  投影到  $W$  上:

$$W^T \Phi(X_i) = \alpha^T \Phi^T \Phi(X_i) = \alpha^T (\Phi(X_1)^T \Phi(X_i), \dots, \Phi(X_N)^T \Phi(X_i))^T$$

$$= \alpha^T (k(X_1, X_i), \dots, k(X_N, X_i))^T = \alpha^T \xi_{X_i} \quad (18)$$

其中,  $\xi_{X_i} = (k(X_1, X_i), \dots, k(X_N, X_i))^T$ 。

**定义 1** 我们称式(17)中的  $\alpha$  为广义核鉴别矢量, 若  $\xi_X = (k(X_1, X), \dots, k(X_N, X))^T$ , 则称  $\xi_X$  为核样本矢量(对应于原始输入样本  $X$ )。

**定义 2** 若  $\xi_{X_1}, \xi_{X_2}, \dots, \xi_{X_N}$  为  $N$  个核样本矢量(分别对应于原始训练样本  $X_1, X_2, \dots, X_N$ ), 令  $K = (\xi_{X_1}, \xi_{X_2}, \dots, \xi_{X_N})$ , 则称  $K$  为核矩阵。

由此定义易知核矩阵  $K$  为  $N \times N$  对称矩阵( $N$  为训练样本总数)。

将特征空间  $H$  中训练样本类均值矢量和总体均值矢量分别投影到  $W$  上:

$$W^T m_i^* = \alpha^T \Phi^T \frac{1}{N_i} \sum_{k=1}^{N_i} \Phi(X_k) = \alpha^T \mu_i \quad (19)$$

$$W^T m_0^* = \alpha^T \Phi^T \frac{1}{N} \sum_{k=1}^N \Phi(X_k) = \alpha^T \mu_0 \quad (20)$$

其中,

$$\mu_i = \left( \frac{1}{N_i} \sum_{k=1}^{N_i} \Phi(X_1)^T \Phi(X_k), \dots, \frac{1}{N_i} \sum_{k=1}^{N_i} \Phi(X_N)^T \Phi(X_k) \right)^T \quad (21)$$

$$\mu_0 = \left( \frac{1}{N} \sum_{k=1}^N \Phi(X_1)^T \Phi(X_k), \dots, \frac{1}{N} \sum_{k=1}^N \Phi(X_N)^T \Phi(X_k) \right)^T \quad (22)$$

则对于一组解矢量  $w_1, \dots, w_d$ , 其中  $w_i = \sum_{k=1}^N a_i^k \Phi(X_k) = \Phi \alpha_i$ ,  $i=1, \dots, d$ ; 此时  $\Phi = (\Phi(X_1), \dots, \Phi(X_N))$ ,  $\alpha_i = (\alpha_i^1, \dots, \alpha_i^N)^T$ 。

根据式(18)、(19)和(20), 我们有

$$\sum_{i=1}^d w_i^T S_b^* w_i = \sum_{i=1}^d \alpha_i^T K_b \alpha_i \quad (23)$$

$$\sum_{i=1}^d w_i^T S_w^* w_i = \sum_{i=1}^d \alpha_i^T K_w \alpha_i \quad (24)$$

$$\sum_{i=1}^d w_i^T S_t^* w_i = \sum_{i=1}^d \alpha_i^T K_t \alpha_i \quad (25)$$

其中,

$$K_b = \sum_{i=1}^c \frac{N_i}{N} (\mu_i - \mu_0) (\mu_i - \mu_0)^T \quad (26)$$

$$K_w = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} (\xi_{X_j} - \mu_i) (\xi_{X_j} - \mu_i)^T \quad (27)$$

$$K_t = \frac{1}{N} \sum_{j=1}^N (\xi_{X_j} - \mu_0) (\xi_{X_j} - \mu_0)^T = K_b + K_w \quad (28)$$

**定义 3** 式(26)、(27)、(28)中的  $K_b$ 、 $K_w$  和  $K_t$  分别称为核类间散布矩阵、核类内散布矩阵和核总体散布矩阵。

由此定义, 易证明  $K_b$ 、 $K_w$  和  $K_t$  均为  $N \times N$  非负对称矩阵( $N$  为训练样本总数)。特别值得注意的是在定义形式上它们非常类似于  $S_b^*$ 、 $S_w^*$  和  $S_t^*$ 。

由式(23)、(25)可知, 高维特征空间  $H$  中广义 Fisher 鉴别准则函数式(14)等价于:

$$J(\bar{W}) = \frac{\sum_{i=1}^d w_i^T S_b^* w_i}{\sum_{i=1}^d w_i^T S_t^* w_i} = \frac{\sum_{i=1}^d \alpha_i^T K_b \alpha_i}{\sum_{i=1}^d \alpha_i^T K_t \alpha_i} = J(\bar{\alpha}) \quad (29)$$

即为

$$J(\bar{\alpha}) = \frac{\sum_{i=1}^d \alpha_i^T K_b \alpha_i}{\sum_{i=1}^d \alpha_i^T K_t \alpha_i} \quad (30)$$

其中,  $\bar{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_d)$ 。

根据式(16), 高维特征空间  $H$  中正交约束条件式(15)等

价于:

$$\begin{aligned} w_i^T w_j &= \alpha_i^T \Phi^T \Phi \alpha_j = \alpha_i^T K \alpha_j = 0, \\ \forall i \neq j, i, j &= 1, \dots, d, K \text{ 为核矩阵} \end{aligned} \quad (31)$$

**定义 4** 我们把  $\alpha_i^T K \alpha_j = 0, (i \neq j)$  称为  $\alpha_i, \alpha_j$  关于矩阵  $K$  共轭正交。

**定义 5** 若其中任意的两个矢量  $\alpha_i, \alpha_j (i \neq j, i, j=1, \dots, d)$  关于矩阵  $K$  共轭正交, 则称  $\alpha_1, \dots, \alpha_d$  关于矩阵  $K$  共轭正交。

由式(30)、(31), 特征空间  $H$  中广义最佳鉴别矢量集  $w_1, \dots, w_d$  可转化为求解下列优化问题得到

$$\left\{ \begin{aligned} &\max(J(\bar{\alpha})) \\ &\alpha_i^T K \alpha_j = 0, \forall i \neq j, i, j = 1, \dots, d, K \text{ 为核矩阵} \\ &\alpha_1, \dots, \alpha_d \in R^N (N \text{ 为训练样本总数}) \end{aligned} \right\} \quad (32)$$

因此, 该优化问题可类似式(9)通过求解广义特征方程的形式得到一组最大化准则函数式(30)且满足约束条件式(31)的广义最佳核鉴别矢量  $\alpha_1, \dots, \alpha_d$ 。

### 2.3 快速核 Foley-Sammon 鉴别分析

由以上的分析可以得出, 在利用 KFSDA 做特征提取时, 当得到前  $r$  个特征向量后, 在计算第  $r+1$  个特征向量时, 需再次求解相应的广义特征方程, 因此计算量非常大。本文给出了一种求解 KFSDA 的快速近似算法<sup>[15]</sup>, 只需一次利用核线性鉴别分析得到相应的特征向量, 无需多次求解广义特征方程, 就可以得到相应的正交特征向量, 因此有效地提高了计算速度。

**定理 2** 假设  $w_1, \dots, w_d$  是通过核线性鉴别准则得到的  $d$  个鉴别矢量, 那么我们可以同样定义快速核 Foley-Sammon 鉴别分析的第一个特征矢量为  $v_1 = w_1$ , 由此假定我们已经得到了前  $k$  个特征向量  $v_1, \dots, v_k (1 \leq k \leq d-1)$ , 那么第  $k+1$  个核正交线性鉴别分析的鉴别矢量求法如下:

$$v_{k+1} = w_{k+1} - \sum_{i=1}^k \frac{v_i^T w_{k+1}}{v_i^T v_i} v_i \quad (33)$$

此定理我们极易证明  $v_{k+1}$  与  $v_1, \dots, v_k$  是满足正交条件的, 因此我们得到了一种取得核正交鉴别矢量的新方法, 由定理 2 确定的最佳鉴别矢量集  $V = (v_1, v_2, \dots, v_d)$ , 其中  $d$  为鉴别矢量个数, 可构成如下变换, 称之为快速核 Foley-Sammon 鉴别分析:

$$Y = V^T \xi_{X_i} \quad (34)$$

其中  $\xi_{X_i}$  定义如式(18)。

由以上的分析可知, 本文的算法是在传统核线性鉴别分析<sup>[11]</sup>(KLDA)的基础上做正交特征向量的提取, 而传统的 KFSDA 在做特征向量的求解过程中, 需要解决一个相应的优化问题, 因此在具体的算法实现过程中需要在求解每一个特征矢量时都对一个相应的广义特征方程做计算, 因此整个求解过程非常耗时。本文提出的这种求解方法, 本质上是对原始样本进行核 Fisher 线性鉴别分析, 所以只需求解一次广义特征方程即可, 因此大大节省了特征矢量集的求解时间, 提高了特征抽取速度。特别是当训练样本数目较多时, 构成的核矩阵  $K$  的维数将非常大, 多次求解广义特征方程是一个非常耗时的过程。

## 3 实验

我们的实验数据采用 ORL 人脸数据库。ORL 人脸数据

(下转第 285 页)

- [3] 刘振英, 方滨兴, 姜誉, 等. 一个调度 Fork-Join 任务图的新算法[J]. 软件学报, 2002, 13(4): 693-697
- [4] Gerasoulis A, Yang T. A Comparison of Clustering Heuristics

- [5] Kwok Y-K, Ahmad I. Static scheduling algorithms for allocating directed task graphs to multiprocessors[J]. ACM Comput. Surv., 1999, 31(4): 406-471

(上接第 275 页)

库包括从 1992 年 4 月到 1994 年 4 月剑桥大学实验室拍摄的一系列人脸图像, 具体为 40 个人, 每个人由不同表情或不同视点的 10 幅图像所构成, 倾斜角度不超过 20 度。人脸库中的部分人脸图像如图 1 所示。



图 1 ORL 人脸数据库部分人脸图像

实验中的训练数据集和测试数据集均随机生成, 分别从每类中取  $\vartheta=4, 5, 6$  构成训练样本集。每次实验中的训练样本集均随机产生, 数据库中训练样本集之外的数据构成测试样本集, 最终抽取得到 39 维特征, 其中的核函数采用 2 种典型的核函数形式:

1) 多项式核函数

$$k(x, y) = (x \cdot y)^d \quad (35)$$

2) 高斯核函数

$$k(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right) \quad (36)$$

最后采用最近邻分类器进行分类。我们的实验中, 在每个不同训练样本数目下均做 10 次不同的实验。表 1 显示了在不同的实验方法中 10 次不同结果的平均识别率(%)和方差比较, 括号中的数据为特征抽取时间(s)。

从表 1 的实验结果可以得出, 在不同的核函数下, 本文提出的基于正交变换的快速核 Foley-Sammon 鉴别分析方法在识别性能上明显优于传统的核线性鉴别分析方法, 并且稍优于核 Foley-Sammon 鉴别分析方法。但是在特征提取的速度上, 本文提出的新方法明显优于传统的核 Foley-Sammon 鉴

表 1 ORL 人脸数据库上的实验结果

# Training sample / class ( $\vartheta$ )	4	5	6	
多项式核函数	KLDA	87.46±2.51 (0.3130)	91.75±1.72 (0.4530)	94.82±1.32 (0.3430)
	KFSLDA	89.75±2.67 (5.2340)	94.90±1.24 (9.2340)	95.81±1.38 (15.8900)
	KFSDA	91.71±2.99 (0.3130)	95.15±1.20 (0.4600)	96.12±1.17 (0.3600)
高斯核函数	KLDA	91.58±1.39 (0.2500)	92.40±2.83 (0.4530)	95.10±2.23 (0.3290)
	KFSLDA	92.67±1.83 (6.4840)	94.60±2.40 (11.4380)	96.13±1.83 (18.7820)
	KFSDA	93.12±1.72 (0.2500)	95.50±1.92 (0.4530)	96.69±1.32 (0.3340)

别分析方法, 并且基本达到了核线性鉴别分析方法的特征提取速度。

**结束语** 抽取复杂样本的非线性特征是模式识别研究的一个关键步骤, 但是 KFSDA 在实际应用中存在计算时耗较大的弱点。本文基于传统的核线性鉴别分析, 给出了一种快速算法, 有效地抽取到了原始样本的非线性正交特征矢量。与传统的核 Foley-Sammon 鉴别分析方法相比较, 本文提出的算法抽取最佳鉴别矢量集速度快, 并且保持了较高的识别率。在 ORL 人脸数据库上的实验结果验证了该算法的有效性。

### 参考文献

- [1] Fisher R. The use of multiple measures in taxonomic problems[J]. Ann. Eugenics., 1936, 7: 79-188
- [2] Wilks S S. Mathematical Statistics[M]. New York, Wiley, 1962
- [3] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs Fisherfaces: Recognition using class specific linear projection[J]. IEEE Trans. Pattern Anal. Machine Intell, 1997, 19(7): 711-720
- [4] Foley D H, Sammon J W Jr. An optimal set of discriminant vectors[J]. IEEE Trans. Computers, 1975, 24(3): 281-289
- [5] Lu J, Platanintis K N, Venetsanopoulos A N. Face Recognition Using Kernel Direct Discriminant Analysis Algorithms[J]. IEEE Transactions on Neural Networks, 2003, 14(1): 117-125
- [6] Vapnik V N. The Nature of Statistical Learning Theory[M]. 2nd ed. New York, John Wiley and Sons, 1998
- [7] Baudat G, Anouar F. Generalized discriminant analysis using a kernel approach[J]. Neural Computation, 2000, 12(10): 2385-2404
- [8] 甘俊英, 张有为. 模式识别中广义核函数 Fisher 最佳鉴别[J]. 模式识别与人工智能, 2002, 15(4): 429-433
- [9] Mika S, Rätsch G, Weston J, et al. Fisher discriminant analysis with kernels[A]//Proceedings of IEEE International Workshop on Neural Networks for Signal Processing[C]. Madison, Wisconsin, August 1999: 41-48
- [10] Müller K-R, Mika S, Rätsch G, et al. An introduction to kernel-based learning algorithms[J]. IEEE Trans. Neural Networks, 2001, 12(2): 181-201
- [11] Yang J, Jin Z, Yang J Y, et al. Essence of Kernel Fisher Discriminant: KPCA plus LDA[J]. Pattern Recognition, 2004, 37(10): 2097-2100
- [12] 高秀梅, 杨静宇, 金忠, 等. 基于核的 Foley-Sammon 鉴别分析与人脸识别[J]. 计算机辅助设计与图形学学报, 2004, 16(7): 962-967
- [13] Zheng W M, Zhao L, Zou C R. Foley-Sammon Optimal Discriminant Vectors Using Kernel Approach[J]. IEEE Trans. Neural Networks, 2005, 16(1): 1-9
- [14] Liu K, Yang J Y, Cheng Y Q, et al. An efficient algorithm for Foley-Sammon optimal set of discriminant vectors by algebraic method[J]. International Journal of Pattern Recognition and Artificial Intelligence, 1992, 6(5): 817-829
- [15] Song F X, Liu S H, Yang J Y. Orthogonalized Fisher discriminant[J]. Pattern Recognition, 2005, 38: 311-313