

基于自适应近邻图嵌入的局部鉴别投影算法

王永茂^{*①②} 徐正光^① 赵珊^②

^①(北京科技大学自动化学院 北京 100083)

^②(河南理工大学计算机科学与技术学院 焦作 454000)

摘要: 针对局部 Fisher 鉴别分析(LFDA)中样本近邻点个数对于最优投影方向的影响以及在度量类间离差度时未考虑不同类别样本近邻点的两点不足之处, 该文提出一种基于自适应近邻图嵌入的局部鉴别投影算法, 根据样本分布以及样本间的相似度自适应计算类内和类间近邻点, 依据类内类间近邻点的个数定义局部类内与类间离差矩阵中的权值矩阵, 通过最大化局部类间离差度最小化局部类内离差度, 得到最优低维子空间。该算法不仅能够保持样本的局部信息, 而且能够保持样本的鉴别信息, 在人工数据以及标准数据库上的实验表明该方法是有效的。

关键词: 模式识别; 降维; 自适应近邻图; 局部 Fisher 鉴别分析; 分类识别

中图分类号: TP391.4

文献标识码: A

文章编号: 1009-5896(2013)03-0633-06

DOI: 10.3724/SP.J.1146.2012.00793

Neighborhood Graph Embedding Based Local Adaptive Discriminant Projection

Wang Yong-mao^{①②} Xu Zheng-guang^① Zhao Shan^②

^①(School of Automation, University of Science and Technology Beijing, Beijing 100083, China)

^②(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract: As a dimensionality reduction algorithm, Local Fisher Discriminant Analysis (LFDA) is faced with two problems: (1) how to select the favorable neighborhood size which may have effect on the optimal projection direction and (2) the neglect of neighborhood relationships between samples of different classes. In order to overcome the drawback of LFDA, a novel dimensionality reduction algorithm called neighborhood graph embedding based Local Adaptive Discriminant Projection (LADP) is proposed in this paper. First, LADP adaptively estimates within-class and between-class neighborhood set according to samples' distribution and similarity. Then local weighted matrices are defined depending on the neighborhood size. Ultimately optimal embedding subspace is gained by maximizing local between-class scatter and minimizing local within-class scatter. LADP can preserve both local information and discriminant information. The experimental results of the toy example and real-word data validate the effectiveness of the proposed algorithm.

Key words: Pattern recognition; Dimensionality reduction; Adaptive neighborhood graph; Local Fisher Discriminant Analysis (LFDA); Classification and recognition

1 引言

降维是高维数据压缩、可视化和分类的重要预处理手段之一。PCA(Principle Component Analysis), FDA(Fisher Discriminant Analysis)^[1]是最流行的降维方法, 但其本质上是线性的, 不能有效描述高维数据的非线性变化。基于流形的非线性降维方法是近年来兴起的一类降维方法, 等距映射(ISOMAP)^[2], 局部线性嵌入(Locally Linear

Embedding, LLE)^[3]和拉普拉斯映射(Laplacian Eigenmap, LE)^[4]是其典型代表, 它们通过在降维过程中保持数据的局部信息来学习非线性流形结构, 但是基于流形的降维方法的一大缺陷是不能直接映射新的测试点^[5], 为了解决这一问题, 许多学者先后提出局部保形投影(Locality Preserving Projection, LPP)^[6], 近邻保形嵌入(Neighborhood Preserving Embedding, NPE)^[7]等基于流形的线性降维算法, 它们分别为LE算法与LLE算法的线性逼近。尽管LPP, NPE在降维过程中能够保持数据的局部信息, 但在降维过程中未利用数据的类别信息, 是一种无监督的降维方法, 而传统的FDA是一种有监督的线

2012-06-12 收到, 2012-11-12 改回

教育部科学技术研究重点项目(210128)和河南省教育厅科学技术研究项目(12B520021)资助课题

*通信作者: 王永茂 wymys2000@hpu.edu.cn

性降维方法,在降维过程中不能保持数据的局部信息。为此,文献[8]将LPP的基本思想引入到FDA中提出了LFDA(Local Fisher Discriminant Analysis)算法,在人脸识别^[9]、人耳识别^[10]等领域取得了较好的效果。然而LFDA在处理高维数据时仍有一些不足:(1)LFDA未考虑不同类别数据间的近邻关系,相距较远的不同类别间的数据在类间离差度量时占据较大比重,以致在处理某些数据时得不到正确的最优投影方向^[11];(2)为描述数据的局部信息,LFDA需要寻找数据的近邻点,同其他基于流形的降维算法一样,近邻点个数的选择对于最优的投影方向影响较大^[12]。

为了解决LFDA存在的不足,本文提出了一种新的局部鉴别分析方法:基于自适应近邻图嵌入的局部鉴别投影(neighborhood graph embedding based Local Adaptive Discriminant Projection, LADP)算法,根据数据分布自适应构造描述局部信息的类内与类间近邻图,避免了近邻点个数对于投影子空间的影响,在得到的低维子空间内,使得相同类别的近邻点尽量靠近,而不同类别的近邻点尽量分离。

2 局部Fisher鉴别分析(LFDA)

2.1 通用图嵌入框架

许多降维方法可以利用通用图嵌入框架进行解释^[13],其形式化描述如下:由 n 个样本组成的样本集记作 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]_{D \times n}$,样本 \mathbf{x}_i 是一个 D 维向量, $l_i \in L = \{1, 2, \dots, N_c\}$ 为样本 \mathbf{x}_i 的类别标号, N_c 为类别总数, n_l 定义为第 l 类样本个数。线性降维是按照某种最优化标准得到一个 $D \times d$ 变换矩阵 \mathbf{V} ,将样本集 \mathbf{X} 投影到低维空间得到 $\mathbf{Y} = \mathbf{V}^T \mathbf{X} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n]_{d \times n}$,其中 \mathbf{y}_i 是 \mathbf{x}_i 的低维投影,维数为 d ,且 $d < D$ 。在此框架中优化准则通常可以表示为

$$\max_{\mathbf{V} \in D \times d} \frac{\text{trace}(\mathbf{V}^T \mathbf{X} (\mathbf{D}_b - \mathbf{W}_b) \mathbf{X}^T \mathbf{V})}{\text{trace}(\mathbf{V}^T \mathbf{X} (\mathbf{D}_w - \mathbf{W}_w) \mathbf{X}^T \mathbf{V})} \quad (1)$$

其中 $\text{trace}(\bullet)$ 表示求矩阵的迹,上标 T 表示矩阵的转置, \mathbf{W}_w 和 \mathbf{W}_b 是权值矩阵,反映了样本之间的关系, \mathbf{D}_w 和 \mathbf{D}_b 是 $n \times n$ 的对角矩阵,对角元素 $D_{w,ii} = \sum_{j=1}^n \mathbf{W}_{w,ij}$, $D_{b,ii} = \sum_{j=1}^n \mathbf{W}_{b,ij}$,式(1)可以通过求解广义特征向量得到最优解。通用图嵌入框架可以将FDA,LFDA等算法纳入其中,不同之处在于权值矩阵 \mathbf{W}_w 和 \mathbf{W}_b 。

2.2 LFDA的权值矩阵

在LFDA中,权值矩阵 \mathbf{W}_w 和 \mathbf{W}_b 定义为

$$\mathbf{W}_{w,ij} = \begin{cases} \mathbf{A}_{ij}(1/n_l), & l_i = l_j = l \\ 0, & l_i \neq l_j \end{cases} \quad (2)$$

$$\mathbf{W}_{b,ij} = \begin{cases} \mathbf{A}_{ij}(1/n - 1/n_l), & l_i = l_j = l \\ 1/n, & l_i \neq l_j \end{cases}$$

\mathbf{A}_{ij} 是样本 \mathbf{x}_i 和 \mathbf{x}_j 之间的一种相似性度量, \mathbf{x}_i 和 \mathbf{x}_j 差别越小, \mathbf{A}_{ij} 值越大,反之越小,这里用高斯函数定义 \mathbf{A}_{ij} ,即

$$\mathbf{A}_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/t), & \mathbf{x}_i \in N_k(\mathbf{x}_j) \text{ 或者 } \mathbf{x}_j \in N_k(\mathbf{x}_i) \\ 0, & \text{其它} \end{cases} \quad (3)$$

其中 $N_k(\mathbf{x}_j)$ 表示样本 \mathbf{x}_j 同类别的 k 个近邻点集合,从式(2)和式(3)可以看出,LFDA中的权值体现了鉴别信息与局部信息,与 \mathbf{x}_i 和 \mathbf{x}_j 是否同类以及是否相邻有关。

在式(3)权值矩阵的定义下,式(1)中 $\mathbf{V}^T \mathbf{X} (\mathbf{D}_b - \mathbf{W}_b) \mathbf{X}^T \mathbf{V}$ 对应为LFDA算法中的局部类间离差矩阵,由不同类别的所有样本点以及同类别近邻点决定, $\mathbf{V}^T \mathbf{X} (\mathbf{D}_w - \mathbf{W}_w) \mathbf{X}^T \mathbf{V}$ 对应为LFDA算法中的局部类内离差矩阵,仅由同类别的近邻点决定。

2.3 LFDA的不足

在LFDA中,最优投影方向依赖于近邻点个数 k 值的选择;同时在计算类间离散度时,未考虑不同类别数据之间的近邻关系,对于某些数据,LFDA得不到正确的最优投影方向,下面通过两个例子加以说明。

图1所示的数据产生自二元正态分布,包含“*”和“+”两类,各有100个样本,每一类又包含左右两个聚类,4个聚类的均值分别为 $(-8, 4)$, $(8, 4)$, $(-8, -4)$, $(8, -4)$,数据的协方差阵均为 $\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$,图中的直线为LFDA方法 $k=5$ 得到的最优投影方向。

(1)不考虑不同类别数据之间的近邻关系对于最优的投影方向的影响 在图1中,聚类A与聚类

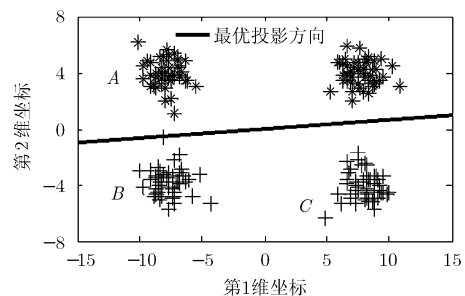


图1 人工数据 1

B 的距离小于聚类 A 与聚类 C 的距离, 显然最优的投影方向应该为垂直方向, 但 LFDA 在类间离差度计算中所有不同类别的数据点间的距离的系数都是相同的, 均为 $1/n$, 距离越大在类间离差度所占的比重也越大, 因此, 在图 1 中, AC 之间的距离占主导地位, 在水平投影方向上 AC 之间的距离要大于在垂直方向上的投影, 因此得到的最优投影方向为水平方向。相反, 如果考虑不同类别数据之间的近邻关系, 这时 C 中的数据点就不会成为 A 中数据点的近邻点, 类间离差度仅由类间近邻点决定, 这时, 应该使得 AB 两个聚类有最大分离程度, 显然在垂直方向上满足要求。因此在定义权值矩阵时需要考虑不同类别数据之间的近邻关系。

图 2 所示的数据产生自二元正态分布, 包含“*”和“+”两类, 每个类别包括 100 个样本点。在图 2 中, 类“*”和类“+”的数据均值均为 $(-3, 0)$, $(3, 0)$, 数据的协方差阵分别为 $\begin{bmatrix} 1 & 0 \\ 0 & 10 \end{bmatrix}$, $\begin{bmatrix} 1 & 0 \\ 0 & 30 \end{bmatrix}$, $\begin{bmatrix} 1 & 0 \\ 0 & 50 \end{bmatrix}$, $\begin{bmatrix} 1 & 0 \\ 0 & 100 \end{bmatrix}$, 从图 2(a)到图 2(d), 水平方向上的方差不变, 垂直方向上的方差依次增加。图中的直线为 LFDA 方法在 $k=5$ 得到的最优投影方向。

(2)近邻点个数 k 的选择对于最优投影方法的影响 很显然, 对于图 2(a)~图 2(d)中的人工数据, 最优的投影方向均为水平方向, 但是数据与其距离

最远的数据点之间的距离随着垂直方向上方差的增加而不断增大, 因为数据点与不同类别的数据点之间的权值均相等, 因此与最远端的数据点之间的距离在类间离差度的计算中占有比较大的比重, 又因为在垂直方向的方差远大于水平方向上的方差, 因此投影方向随着方差的增加而逐渐向垂直方向靠近, 这时就需要增加类内近邻点的个数, 也就是 k 值来抵消远端数据点在类间离差度中所占的比重, 图 3 为对于图 2(d)中的数据, 投影方向随近邻点个数 k 的变化情况, 图中的直线代表不同近邻点个数 k 对应的最优投影方向。

从图 3 可以看出随着 k 值的增加, 投影方向逐渐向水平方向靠近。因此近邻点个数 k 对于最优的投影方向有较大的影响, 需要根据数据的分布自适应确定数据之间的近邻关系。

3 基于自适应近邻图嵌入的局部鉴别分析算法

基于上节提到的 LFDA 的不足, 本文提出一种新的局部鉴别分析算法: 基于自适应近邻图嵌入的局部鉴别投影算法(LADP)。LADP 算法的步骤如下:

- 步骤 1 根据数据分布特性以及数据间的相似度自适应计算数据类内以及类间的近邻点;
- 步骤 2 根据数据的类内类间近邻点的个数定义局部类内与类间离差矩阵中的权值矩阵;

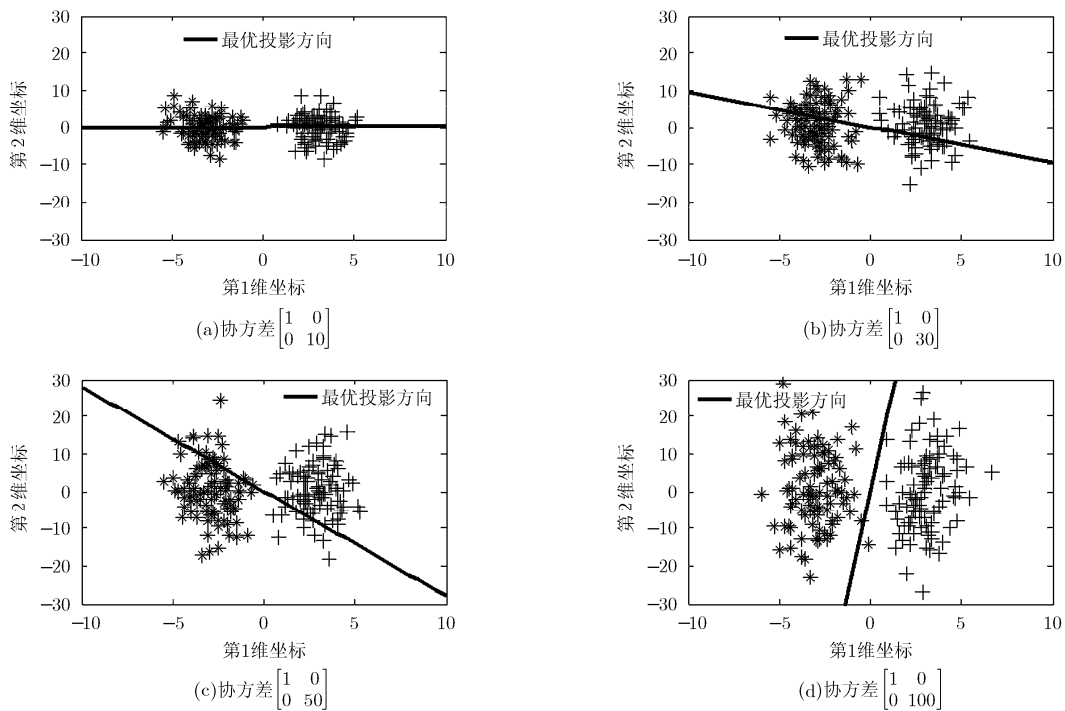



图 2 人工数据 2

图3 LFDA 在不同 k 值下的最优投影方向对比

步骤 3 最大化局部类间离差度最小化局部类内离差度, 得到最优子空间。

3.1 自适应近邻点计算

首先根据式(4)计算样本 \mathbf{x}_i 与所有其他样本之间的平均相似度 $AS(\mathbf{x}_i)$ 。

$$AS(\mathbf{x}_i) = \frac{1}{n} \sum_{m=1}^n \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_m\|^2}{\beta}\right) \quad (4)$$

其中参数 β 取式(5)定义的所有样本之间的欧式距离的平均值。

$$\beta = \frac{1}{n^2} \sum_{i,j=1}^n \|\mathbf{x}_i - \mathbf{x}_j\|^2 \quad (5)$$

接着, 根据式(6)和式(7)自适应确定 \mathbf{x}_i 的类内近邻点集合 $N_w(\mathbf{x}_i)$ 以及 \mathbf{x}_i 的类间近邻点集合 $N_b(\mathbf{x}_i)$ 。

$$N_w(\mathbf{x}_i) = \left\{ \mathbf{x}_j \mid l_j = l_i, \exp\left(-\frac{\|\mathbf{x}_j - \mathbf{x}_i\|^2}{\beta}\right) > AS(\mathbf{x}_i) \right\} \quad (6)$$

$$N_b(\mathbf{x}_i) = \left\{ \mathbf{x}_j \mid l_j \neq l_i, \exp\left(-\frac{\|\mathbf{x}_j - \mathbf{x}_i\|^2}{\beta}\right) > AS(\mathbf{x}_i) \right\} \quad (7)$$

根据式(6)和式(7)的定义, $N_w(\mathbf{x}_i)$ 为相似度大于平均相似度的与 \mathbf{x}_i 同类别的样本集合, $N_b(\mathbf{x}_i)$ 是相似度大于平均相似度的与 \mathbf{x}_i 不同类别的样本集合。

3.2 权值矩阵

这里, 依据样本的类内类间近邻点的个数定义式(1)中的权值矩阵 \mathbf{W}_w 和 \mathbf{W}_b :

$$\mathbf{W}_{w,ij} = \begin{cases} \frac{1}{k_w(i)}, & \mathbf{x}_i \in N_w(\mathbf{x}_j) \text{ 或者 } \mathbf{x}_j \in N_w(\mathbf{x}_i) \\ 0, & \text{其它} \end{cases} \quad (8)$$

$$\mathbf{W}_{b,ij} = \begin{cases} \frac{1}{k_w(i) + k_b(i)} - \frac{1}{k_w(i)}, & \mathbf{x}_i \in N_w(\mathbf{x}_j) \text{ 或者 } \mathbf{x}_j \in N_w(\mathbf{x}_i) \\ \frac{1}{k_w(i) + k_b(i)}, & \mathbf{x}_i \in N_b(\mathbf{x}_j) \text{ 或者 } \mathbf{x}_j \in N_b(\mathbf{x}_i) \\ 0, & \text{其它} \end{cases} \quad (9)$$

其中 $k_w(i)$ 为样本点 \mathbf{x}_i 同类别的近邻点的个数, 其值为类内近邻点集合 $N_w(\mathbf{x}_i)$ 中样本点的个数, $k_b(i)$ 为样本点 \mathbf{x}_i 不同类别的近邻点的个数, 其值为类间近邻点集合 $N_b(\mathbf{x}_i)$ 中样本点的个数。

3.3 最优嵌入

为提高算法的灵活性, 与式(1)优化准则不同, 在本文采用的优化准则中, 类间离差度与类内离差度所占的比重不同。

最大化式(1)等价于:

$$\min_{\mathbf{V}} \text{trace}(\mathbf{V}^T \mathbf{X} (\mathbf{D}_w - \mathbf{W}_w) \mathbf{X}^T \mathbf{V}) \quad (10)$$

$$\max_{\mathbf{V}} \text{trace}(\mathbf{V}^T \mathbf{X} \mathbf{L}_b \mathbf{X}^T \mathbf{V}) \quad (11)$$

其中 $\mathbf{L}_b = \mathbf{D}_b - \mathbf{W}_b$ 。

在约束条件 $\mathbf{V}^T \mathbf{X} \mathbf{D}_w \mathbf{X}^T \mathbf{V} = \mathbf{I}$ 下, 最小化式(10)等价于最大化式(12):

$$\max_{\mathbf{V}} \text{trace}(\mathbf{V}^T \mathbf{X} \mathbf{W}_w \mathbf{X}^T \mathbf{V}) \quad (12)$$

因此, 由式(11)和式(12), 最优化问题变为

$$\left. \begin{aligned} \max_{\mathbf{V}} \text{trace}(\mathbf{V}^T \mathbf{X} (\alpha \mathbf{L}_b + (1-\alpha) \mathbf{W}_w) \mathbf{X}^T \mathbf{V}) \\ \text{s.t. } \mathbf{V}^T \mathbf{X} \mathbf{D}_w \mathbf{X}^T \mathbf{V} = \mathbf{I} \end{aligned} \right\} \quad (13)$$

其中 $0 \leq \alpha \leq 1$ 为调节参数, 令 $\mathbf{B} = \alpha \mathbf{L}_b + (1-\alpha) \mathbf{W}_w$, 式(13)变为

$$\left. \begin{aligned} \max_{\mathbf{V}} \text{trace}(\mathbf{V}^T \mathbf{X} \mathbf{B} \mathbf{X}^T \mathbf{V}) \\ \text{s.t. } \mathbf{V}^T \mathbf{X} \mathbf{D}_w \mathbf{X}^T \mathbf{V} = \mathbf{I} \end{aligned} \right\} \quad (14)$$

式(14)的最优化问题转换为广义特征向量的求解:

$$\mathbf{X} \mathbf{B} \mathbf{X}^T \mathbf{V} = \lambda \mathbf{X} \mathbf{D}_w \mathbf{X}^T \mathbf{V} \quad (15)$$

令 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_d$ 为式(15)最大的 d 个特征值对应的特征向量, 则最优的变换矩阵为 $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_d]_{D \times d}$ 。

3.4 时间复杂度分析

LFDA 与 LADP 算法的时间复杂度主要由两个方面决定: (1)类内类间近邻点的计算; (2)广义特征向量的求解。

在 LFDA 算法中, 类内类间近邻点计算的时间复杂度为 $O(Dn^2 + kn^2)$, 其中 $O(Dn^2)$ 代表计算任意两个样本的欧式距离的时间复杂度, D 为样本的维数, n 为样本的个数, $O(kn^2)$ 代表寻找同类别 k 个近邻点的时间复杂度, 又有局部类内类间离差矩阵均为 $D \times D$ 矩阵, 求解广义特征向量的时间复杂度为 $O(D^3)$, 可知 LFDA 算法的时间复杂度为 $O(Dn^2 + kn^2 + D^3)$, 由于 k 远小于样本维数 D 和样本个数 n , $O(kn^2)$ 的变化趋势远小于 $O(Dn^2)$ 与 $O(D^3)$, 所以 LFDA 算法的时间复杂度近似于 $O(Dn^2 + D^3)$ 。LADP 与 LFDA 区别在于自适应确定类内类间近邻点, 计算任意两个样本的相似度的时间复杂度为 $O(Dn^2)$, 得到每一个样本的平均相似

度的时间复杂度为 $O(n^2)$ ，与平均相似度进行比较确定类内和类间近邻点集合的时间复杂度为 $O(n^2)$ ，求解广义特征向量的时间复杂度为 $O(D^3)$ ，所以LADP算法的时间复杂度为 $O(Dn^2 + 2n^2 + D^3)$ ，由于 $O(2n^2)$ 的变化趋势远小于 $O(Dn^2)$ 与 $O(D^3)$ ，LADP算法的时间复杂度近似于 $O(Dn^2 + D^3)$ 。因此LADP与LFDA的时间复杂度相当，仅由样本的个数 n 和维数 D 决定。

4 实验与结果

为了评估算法的性能，我们设计两类实验，实验1将LADP应用分类任务，比较LADP与经典的PCA, FDA以及LFDA等算法的分类性能；实验2通过低维特征抽取时间比较LFDA与LADP算法的运算效率。

4.1 分类识别

为了验证本文提出的LADP算法在分类识别任务中的有效性，本文在ORL人脸库，COIL20图像库以及ISOLET语音库上进行实验，比较LADP算法与PCA^[1]，FDA^[1]，LFDA^[8]等算法的分类识别性能。

4.1.1 数据集介绍 ORL人脸库是由英国剑桥大学建立，共有40个人，每人10张图像，共有400张人脸图像，图像的面部表情和面部细节有着不同程度的变化，人脸姿势也有相当的程度变化，比较充分地反映了同一人不同人脸图像的变化和差异，图4是ORL人脸库的部分样本。COIL20图像库由20个物体的1440幅图像组成，每一个物体旋转一周每隔 5° 采集一幅图像共有72幅图像，图5是COIL20图像库中的部分样本。ORL人脸库以及COIL20图像库中的图像经剪切后大小均为 32×32 ，用一个1024维的向量表示。ISOLET语音库是UCI机器学习数据集中的标准数据库，由30个人的1560个语音样本组成，采集每个人诵读26个字母的语音各2次共52个语音样本，每一个语音样本用一个617维的向量表示。



图4 ORL人脸数据库中的部分人脸图像



图5 COIL20图像库中的部分样本图

4.1.2 调节参数 α 选择 本节讨论LADP算法中类内和类间离散度的调节参数 α 对于识别性能的影响。这里采用交叉验证方法进行调节参数 α 的选择。在ORL人脸库，COIL20图像库以及ISOLET语音库上分别随机选择4幅图像作为训练样本，其余所有图像作为测试样本，进行10次重复试验，取10次的平均识别率，图6显示了在调节参数 α 不同取值的情况下，LADP算法的平均识别率。可以看出，调节参数 α 对于识别性能有较大的影响， α 的值越大，识别性能越好，在后续的实验取 $\alpha = 0.9$ 。

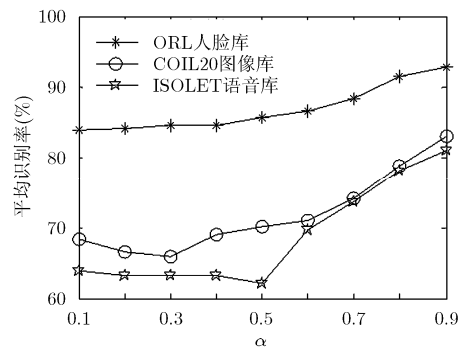


图6 平均识别率随调节参数 α 的变化情况

4.1.3 识别性能比较 本节分别在ORL人脸库，COIL20图像库以及ISOLET语音库对比本文提出的LADP算法与PCA, FDA, LFDA等算法的识别性能，使用最近邻分类器完成分类识别。在实验中，从每类图像中随机选取 i 张图像作为训练集，剩下的作为测试集，重复进行10次，共获得10对不同的训练集和测试集，用 $iTrain$ 表示不同数量的训练样本数，取10次实验的平均识别率。图7~图9分别为ORL人脸库，COIL20图像库以及ISOLET语音库上的平均最高识别率。

4.1.4 讨论

(1)由于实验所用的样本的维数很高，其存在的冗余信息可能影响图像的识别率，从实验结果也验证了这一点，在PCA, FDA, LFDA以及LADP等降维算法得到的低维子空间内的识别率高于在原始空间内的识别率；

(2)FDA, LFDA以及LADP的识别率高于PCA方法，这是因为FDA, LFDA以及LADP在寻找最优子空间的过程中利用了数据的鉴别信息，而PCA寻找的最优子空间其重构误差最小，没有考虑有利于分类的鉴别信息；

(3)LFDA与LADP在降维的过程中能够保持数据的局部信息，尤其在训练样本不足的情况下，其性能要优于全局降维方法FDA；




图7 ORL人脸数据库上平均最高识别率




图8 COIL20图像库上的平均最高识别率




图9 ISOLET语音库上的平均最高识别率

(4)LADP 的识别率是最高的,这主要取决于以下几个方面:(a)LADP 充分考虑类内近邻以及类间近邻点对于分类结果的影响;(b)自适应确定类内以及类间近邻点的个数,避免了近邻点个数对于分类结构的影响;(c)在定义目标函数时,类内离差度与类间离差度所占比重不同。

4.2 低维特征抽取时间比较

本节利用低维特征抽取所花费的时间来比较 LFDA 与 LADP 算法的效率。LFDA 与 LADP 算法采用 matlab7.0 编写,在配置主频为 2.93 GHz 的 CPU(Intel 酷睿 2 双核 E7500)以及 2 G 内存的计算机上运行。在 ORL 人脸库,COIL20 图像库以及 ISOLET 语音库上分别随机选择 4 幅图像作为训练样本,其余所有图像作为测试样本,表 1 为 LFDA 与 LADP 算法进行低维特征抽取所花费时间。可以看出 LFDA 与 LADP 算法进行低维特征抽取所花费的时间相当,也就是说 LADP 算法在提高识别性能的同时算法的执行时间并没有增加。

表 1 低维特征抽取时间(s)

方法	ORL 人脸库	COIL20 图像库	ISOLET 语音库
LFDA	3.82	0.85	1.22
LADP	3.81	0.81	1.17

5 结束语

在分析了 LFDA 算法不足的基础上,本文提出了一种新的基于局部保持的鉴别分析方法:基于自适应近邻图嵌入的鉴别投影方法,自适应计算数据的近邻点集合,不仅能够很好保持流行的局部结构,同时也能够保持数据的鉴别信息,在人工数据以及标准数据库上均取得了较好的效果。LADP 本质上是一种线性降维方法,在应用 LADP 算法时,需要将图像的 2 维结构转换为向量形式,这就容易出现小样本问题,基于张量表示的 LADP 算法是下一步研究的重点。

参考文献

- [1] Martinez A and Kak A. PCA versus LDA[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(2): 228-233.
- [2] Tenenbaum J, Silva V, and Langford J. A global geometric framework for nonlinear dimensionality reduction[J]. *Science*,

2000, 290(5500): 2319-2323.

- [3] Roweis S and Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, 290(5500): 2323-2326.
 - [4] Belkin M and Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, 15(6): 1373-1396.
 - [5] 张大尉,朱善安. 基于核邻域保持判别嵌入的人脸识别[J]. *浙江大学学报(工学版)*, 2011, 45(10): 1842-1847.
Zhang Da-wei and Zhu Shan-an. Face recognition based on kernel neighborhood preserving discriminant embedding[J]. *Journal of Zhejiang University(Engineering Science)*, 2011, 45(10): 1842-1847.
 - [6] He Xiao-fei and Niyogi P. Locality preserving projections[C]. *Proceedings of the 16th Advances in Neural Information Processing Systems*, Vancouver, 2003: 153-160.
 - [7] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding[C]. *Proceedings of the 10th IEEE International Conference on Computer Vision*, Beijing, 2005: 1208-1213.
 - [8] Sugiyama M. Dimensionality reduction of multimodal labeled data by local fisher discriminant analysis[J]. *Journal of Machine Learning Research*, 2007, 8(5): 1027-1061.
 - [9] Huang Hong, Feng Hai-liang, and Peng Cheng-yu. Complete local Fisher discriminant analysis with Laplacian score ranking for face recognition[J]. *Neurocomputing*, 2012, 89(7): 64-77.
 - [10] Huang Hong, Liu Jiamin, Feng Hailiang, et al. Ear recognition based on uncorrelated local Fisher discriminant analysis[J]. *Neurocomputing*, 2011, 74(17): 3103-3113.
 - [11] 谢钧,刘剑. 一种新的局部判别投影方法[J]. *计算机学报*, 2011, 34(11): 2243-2250.
Xie Jun and Liu Jian. A new local discriminant projection method[J]. *Chinese Journal of Computers*, 2011, 34(11): 2243-2250.
 - [12] Raducanu B and Dornaika F. A supervised non-linear dimensionality reduction approach for manifold learning[J]. *Pattern Recognition*, 2012, 45(6): 2432-2444.
 - [13] 俞璐,谢钧,朱磊. 一种基于目标空间的局部判别投影方法[J]. *电子与信息学报*, 2011, 33(10): 2390-2395.
Yu Lu, Xie Jun, and Zhu Lei. A local discriminant projection method based on objective space[J]. *Journal of Electronics & Information Technology*, 2011, 33(10): 2390-2395.
- 王永茂: 男, 1976 年生, 副教授, 博士生, 研究方向为图像处理与模式识别。
徐正光: 男, 1959 年生, 教授, 博士生导师, 研究方向为图像处理与模式识别。
赵珊: 女, 1975 年生, 副教授, 博士, 研究方向为模式识别、基于内容的图像检索。