

基于双邻接图正交近邻保持投影的人脸识别算法

薛潇宇¹ 马小虎²

(苏州大学计算机科学与技术学院 苏州 215006)¹

(浙江大学计算机辅助设计与图形学国家重点实验室 杭州 310058)²

摘要 正交保持投影(ONPP)是经典的图嵌入降维技术,已经成功地应用到人脸识别中,其保持了高维数据的局部性和整体几何结构。监督的ONPP通过建立同类邻接图来最小化同类局部重构误差,寻找最优的低维嵌入,但是它只使用了类内信息,这会导致异类数据点间的结构不够明显。因此,提出了基于双邻接图的正交近邻保持投影(DAG-ONPP)算法。通过建立同类邻接图与异类邻接图,在数据嵌入到低维空间后同类近邻重构误差尽量小,异类近邻重构误差更加明显。在ORL, Yale, YaleB和PIE人脸库上的实验结果表明,与其他经典算法相比,所提方法有效提高了分类能力。

关键词 监督学习,人脸识别,流型学习,正交近邻保持投影,双邻接图

中图分类号 TP391.4 文献标识码 A DOI 10.11896/j.issn.1002-137X.2017.08.006

Double Adjacency Graphs Based Orthogonal Neighborhood Preserving Projections for Face Recognition

XUE Xiao-yu¹ MA Xiao-hu²

(School of Computer Science and Technology, Soochow University, Suzhou 215006, China)¹

(State Key Laboratory of CAD&CG, Zhejiang University, Hangzhou 310058, China)²

Abstract Orthogonal neighborhood preserving projections (ONPP) is a typical graph-based dimensionality reduction technique, which preserves not only the locality but also the local and global geometry of the high dimensional data, and has been successfully applied to face recognition. The supervised ONPP tries to find the optimal embedding of low-dimensional subspace by setting up homogeneous adjacency graph and minimizing the homogeneous local reconstruction errors. However, it only uses the homogeneous information, which leads to unobvious structure of heterogeneous data. Motivated by this fact, we proposed a novel method called double adjacency graphs based orthogonal neighborhood preserving projections (DAG-ONPP). By introducing homogeneous and heterogeneous neighbor adjacency graphs, the homogeneous reconstructing errors will be as small as possible and the heterogeneous reconstructing errors will be more obvious after data being embedded in low-dimensional subspace. The results of the experiments on the ORL, Yale, YaleB and PIE databases demonstrate that the proposed method can markedly improve the classification ability of the original method and outperforms the other typical methods.

Keywords Supervised learning, Face recognition, Manifold learning, Orthogonal neighborhood preserving projections, Double adjacency graphs

1 引言

维数约简是机器学习和模式识别中一种有效且至关重要的技术,其已经成功应用到各种实际应用之中,比如人脸识别和图像检索。维数约简技术不仅可以降低由高维数据带来的计算复杂度,还可以有效地提高分类能力。在一般的降维框架^[1]中,传统的降维可以被分为非监督和监督的降维技术。非监督的降维技术处理数据时不使用数据的标签信息,常见的有主成分分析(Principle Component Analysis, PCA)^[2-3]、局

部保持投影(Locality Preserving Projection, LPP)^[4]、局部线性嵌入(Locally Linear Embedding, LLE)^[5]、近邻保持嵌入(Neighborhood Preserving Embedding, NPE)^[6]等。监督的降维技术的目的在于利用数据的标签信息在低维空间中获得较高的分类效果,同时降低计算的复杂度。典型的监督性降维方法有线性判别分析(Linear Discriminant Analysis, LDA)^[7]、边界Fisher分析(Marginal Fisher Analysis, MFA)^[1,7]、监督最优局部保持投影(Supervised Optimal Locality Preserving Projection, SoLPP)^[8]、监督的正交近邻保持

到稿日期:2016-07-08 返修日期:2016-08-19 本文受江苏省自然科学基金(BK20141195),浙江大学CAD&CG国家重点实验室基金(A1520)资助。

薛潇宇(1991-),男,硕士,主要研究方向为图形图像处理与模式识别, E-mail: 20145227008@stu.suda.edu.cn; 马小虎(1964-),男,博士,教授,主要研究方向为图形图像处理、模式识别。

投影(Orthogonal Neighborhood Preserving Projections, ONPP)^[9]、局部判别嵌入(Local Discriminant Embedding, LDE)^[10]。

PCA通过最大化训练样本的协方差矩阵来获得最优的投影向量,但是它并不适合处理流形数据。LLE通过使用近邻样本线性重构每个数据点来体现局部几何特征,然后寻找同样满足该线性重构的低维嵌入。但是,LLE仅适用于训练数据,无法运用于外来的测试样本,即LLE受到了样本外问题的困扰。NPE和ONPP作为LLE的线性估计算法,在保持数据的局部流形结构的同时还解决了样本外问题。NPE和ONPP的主要区别在于解决广义特征值问题时使用了不同的限制条件。LPP找到的低维嵌入同样可以保持局部信息,并且可以简单地扩展到新样本点。NPE和LPP算法由于都是非监督的,因此在分类任务中并不能表现出令人满意的效果。

LDA通过最大化类间散布矩阵和最小化类内散布矩阵来寻找投影方向。尽管LDA是一种不错的降维技术,但是它仍然受到一些问题的困扰。比如,LDA仅保留了数据的整体欧氏结构,没能发掘隐藏在低维数据内部的非线性结构。为了解决这个问题,文献[1,7]扩展了LDA,提出了边界Fisher分析,通过建立类内邻接图和类间邻接图来保持数据的局部结构。监督的ONPP用同类的样本点来代替近邻样本点,成功地保持了高维数据的局部性和整体几何结构。但是,由于它只使用了类内信息,导致异类数据点间的结构不够明显,进而会导致降维后类内与类间结构不平衡,在低维嵌入中会出现异类重构误差小于同类重构误差的情况,这会影响后续的分类能力。

为了解决ONPP对类间信息不够敏感的问题,本文提出了新的监督性降维算法,即基于双邻接图的正交保持投影算法(Double Adjacency Graphs Based Orthogonal Neighborhood Preserving Projections, DAG-ONPP)。在DAG-ONPP中,每个样本寻找同类和异类的近邻点,从而建立同类邻接图和异类邻接图;在保证同类局部重构误差尽量小的前提下,使得异类点重构误差更加明显。此外,DAG-ONPP在计算过程中无需对矩阵进行求逆,因此矩阵奇异问题也可以被避免。

2 相关工作

2.1 维数约简问题

线性维数约简问题可以描述如下。给定一个数据集 $X = [x_1, \dots, x_m]$ in \mathbb{R}^n , 寻找一个变换矩阵 P , 可以将 m 个数据点映射到 $Y = [y_1, \dots, y_m]$ in \mathbb{R}^d ($d \ll n$), 其中 y_i “表示”降维后的 x_i , $y_i = P^T x_i$ 。本文中的方法适用于 $x_1, \dots, x_m \in M$, 其中 M 是嵌入在 \mathbb{R}^n 中的非线性流形。

2.2 边界Fisher分析

在MFA中,定义了类内邻接矩阵和类间邻接矩阵,分别建立两个邻接图:类内邻接图和类间邻接图。对于每一个样本 x_i , 定义类内邻接矩阵 W^w , 如果 x_j 属于 x_i 同类的 k 近邻, 那么 $W_{ij}^w = W_{ji}^w = 1$, 否则 $W_{ij}^w = W_{ji}^w = 0$; 在类间邻接图中, 对于每一个样本 x_i , 定义类间邻接矩阵 W^b , 如果 x_j 属于 x_i 异类的 k 近邻, 那么 $W_{ij}^b = W_{ji}^b = 1$, 否则 $W_{ij}^b = W_{ji}^b = 0$ 。

MFA通过边界Fisher准则寻找最佳投影方向:

$$\min_P \frac{\text{tr}(P^T X(D^w - W^w) X^T P)}{\text{tr}(P^T X(D^b - W^b) X^T P)} \quad (1)$$

其中, $\text{tr}()$ 表示矩阵的迹, $D_i^w = \sum_j W_{ij}^w$, $D_i^b = \sum_j W_{ij}^b$, P 由最优的 d 个投影向量构成。

2.3 正交近邻保持投影(ONPP)

在ONPP中,每个数据点 x_i 可以被它的 k 个最近邻线性重构。因此首先构造邻接图,对于每个数据点 x_i , 如果数据点 x_j 是其 k 近邻, 那么从 x_i 到 x_j 生成一条有向边。定义权值矩阵 W , 如果从 x_i 到 x_j 存在有向边, 则存在权值 W_{ij} , 否则为零。 W 可以通过求解如下最小化问题获得:

$$\begin{aligned} \min \sum_i \|x_i - \sum_j W_{ij} x_j\|^2 \\ \text{s. t. } \sum_j W_{ij} = 1 \end{aligned} \quad (2)$$

ONPP算法认为高维空间中数据点的重构关系同样会在低维空间中保持,因此线性变换 P 可以通过求解以下最小化问题获得:

$$\begin{aligned} \min \text{tr}(P^T X M X^T P) \\ \text{s. t. } P^T P = I \end{aligned} \quad (3)$$

其中, $M = (I - W^T)(I - W)$ 。

投影矩阵 P 可以通过求解如下广义特征值问题获得:

$$X M X^T p = \lambda p \quad (4)$$

P 由式(4)中最小的 d 个特征值所对应的特征向量构成。

2.4 监督的正交近邻保持投影

在监督的ONPP中,用每个数据点 x_i 的同类数据点来取代 k 近邻,因此监督的ONPP构建邻接图时无需选取参数 k , 其他过程与非监督的ONPP完全一样。

3 基于双邻接图的正交近邻保持投影

本节介绍提出的新的监督子空间降维算法,即基于双邻接图的正交近邻保持投影算法(DAG-ONPP)。监督的ONPP能够保持同类近邻点最小的重构误差,但是并没有考虑到异类重构误差的大小。在DAG-ONPP中,与MFA一样,建立两个邻接图,即类内邻接图和类间邻接图,在保证同类局部重构误差尽量小的前提下,可保证异类点重构误差更加明显,从而平衡了类内与类间结构的关系。

3.1 DAG-ONPP

首先定义数据点 x_i 的同类和异类 k 近邻集合 $N_{k1}^+(x_i)$ 和 $N_{k2}^-(x_i)$, 建立类内、类间邻接图,构造过程与ONPP一样,并且定义类内权值矩阵 W^w 和类间权值矩阵 W^b , 其计算方式与ONPP相同。

为了得到最佳投影方向,参考MFA的方式分别构造类内重构误差函数和类间重构误差函数。类内重构误差函数构造如下:

$$\begin{aligned} \Phi(P) = \sum_i \|P^T x_i - \sum_j W_{ij}^w P^T x_j\|^2 \\ = \text{tr}(P^T X M^w X^T P) \Phi(P) \end{aligned} \quad (5)$$

其中, $M^w = (I - W^w)^T (I - W^w)$ 。

类间重构误差函数构造如下:

$$\Psi(P) = \sum_i \|P^T x_i - \sum_j W_{ij}^b P^T x_j\|^2$$

$$= \text{tr}(P^T X M^b X^T P) \quad (6)$$

其中, $M^b = (I - W^b)^T (I - W^b)$ 。

此处利用最大化边缘准则^[17]最大化类间重构误差,并且最小化类内重构误差:

$$\begin{cases} \max \Theta(P) = \Psi(P) - \Phi(P) \\ P^T P = I \end{cases} \quad (7)$$

其中, $\Theta(P)$ 描述了投影空间中每个数据点与其同类和异类近邻点的关系,并且给定约束条件 $P^T P = I$,使得投影向量相互正交,正交的投影矩阵可以更好地保持局部结构,增强判别能力^[11],并且可以避免后续矩阵奇异的问题。根据矩阵迹的性质,可以把 $\Theta(P)$ 写成如下形式:

$$\begin{aligned} \Theta(P) &= \Psi(P) - \Phi(P) \\ &= \text{tr}(P^T X (M^b - M^w) X^T P) \\ &= \text{tr}(P^T X S X^T P) \end{aligned} \quad (8)$$

其中 $S = M^b - M^w$,因此最优化问题式(7)可以写成如下形式:

$$\begin{cases} \max_P \Theta(P) = \text{tr}(P^T X S X^T P) \\ P^T P = I \end{cases} \quad (9)$$

为了求解式(9),我们给出如下定理。

定理 1 如果 S 是一个实对称矩阵,那么最优化问题式(9)等价于矩阵 $X S X^T$ 的特征分解。设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{i-1} \geq \lambda_i \geq \dots \geq \lambda_D$ 是 $X S X^T$ 的特征值,并且 p_i 为 λ_i 对应的特征向量,则最优的 P 由前 d 个最大特征值对应的特征向量构成,即:

$$P = [p_1, \dots, p_d] \quad (10)$$

证明:因为 $M^b = (I - W^b)^T (I - W^b)$ 是实对称矩阵, $M^w = (I - W^w)^T (I - W^w)$ 也是实对称矩阵,则 $S = M^b - M^w$ 是实对称矩阵^[12]。为了解决问题(9),根据拉格朗日乘子法构造拉格朗日方程:

$$L(p_i, \lambda_i) = \sum_{i=1}^d (p_i^T X S X^T p_i - \lambda_i (p_i^T p_i - 1)) \quad (11)$$

其中 $\lambda_i (i=1, 2, \dots, d)$ 是拉格朗日乘子。求 $L(p_i, \lambda_i)$ 对 p_i 的偏导数:

$$\frac{\partial L(p_i, \lambda_i)}{\partial p_i} = 2 X S X^T p_i - 2 \lambda_i p_i = 0 \quad (12)$$

令式(12)为 0 可以得到:

$$X S X^T p_i = \lambda_i p_i \quad (13)$$

因此,可以通过广义特征方程的最大特征值来获得最优投影矩阵 P 。证毕。

定理 2 给定 $X S X^T$ 的特征值 $\lambda_1 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_D$,问题(9)的最优解的形式为:

$$P = [p_1, \dots, p_d] \quad (14)$$

证明:根据定理 1 可知 S 是一个实对称矩阵。由于实对称矩阵的特征值是实数,因此 S 的特征值也都是实数。由于 $X S X^T$ 是非正定矩阵,因此其特征值可能是正、负或者是零。

根据式(13),将式(9)中的目标函数改写为:

$$\begin{aligned} \text{tr}(P^T X S X^T P) &= \sum_{i=1}^d p_i^T X S X^T p_i = \sum_{i=1}^d p_i^T \lambda_i p_i \\ &= \sum_{i=1}^d \lambda_i p_i^T p_i = \sum_{i=1}^d \lambda_i \end{aligned} \quad (15)$$

为了最大化 $\text{tr}(P^T X S X^T P)$,应该选择所有最大特征值或

者 $\sum_{i=1}^d \lambda_i$ 。因此当 $\text{tr}(P^T X S X^T P)$ 取得最大值 $\sum_{i=1}^d \lambda_i$ 时,式(9)的最优解必定为 $P = [p_1, \dots, p_d]$ 。证毕。

根据定理 1 和定理 2 可知,当指定维度 d 时,最优的投影矩阵 P 仅仅由最大的 d 个特征值所对应的特征向量构成。

一旦用 DAG-ONPP 从训练数据中学习出投影矩阵 P ,任何新的数据点 $x_i \in \mathbb{R}^n$ 可以被表示成 $y_i = P^T x_i$, $y_i \in \mathbb{R}^d$ 。DAG-ONPP 的细节将在算法 1 中给出。

算法 1 DAG-ONPP

输入:训练集 $X = [x_1, \dots, x_m] \in \mathbb{R}^n$,子空间维数 d

输出:投影矩阵 P

1. 寻找每个数据点的同类 k_1 近邻 $N_{k_1}^+(x_i)$ 和异类 k_2 近邻 $N_{k_2}^-(x_i)$ 。
2. 计算同类权值矩阵 W^w 和异类权值矩阵 W^b ,计算方法如下。

$$\begin{aligned} \min \sum_i \|x_i - \sum_j W_{ij}^w x_j\|^2 \\ \text{s. t. } \sum_j W_{ij}^w = 1 \end{aligned} \quad (16)$$

$$\begin{aligned} \min \sum_i \|x_i - \sum_j W_{ij}^b x_j\|^2 \\ \text{s. t. } \sum_j W_{ij}^b = 1 \end{aligned} \quad (17)$$

3. 通过求解下列特征方程来计算投影矩阵 P :

$$X S X^T p = \lambda p \quad (18)$$

其中 $S = M^b - M^w$, $M^b = (I - W^b)^T (I - W^b)$, $M^w = (I - W^w)^T (I - W^w)$, $I = \text{diag}(1, \dots, 1)$ 。

取式(18)的前 d 个最大特征值对应的特征向量构成投影矩阵 $P = [p_1, \dots, p_d]$ 。

3.2 与 NPE 和 ONPP 的比较

DAG-ONPP, NPE 和 ONPP 都是基于图嵌入的降维技术。NPE 利用流形中局部线性重构的性质,先建立权值矩阵,然后利用每个数据点和其近邻的线性重构来描述它们之间的关系,最后将这个关系在低维空间中保持下来。NPE 很好地保持了数据点之间的局部关系。DAG-ONPP 和监督的 ONPP 可以看作是 NPE 的监督性扩展算法。监督的 ONPP 用同类的样本点来代替近邻样本点,同时保证了投影矩阵是正交的,其成功地保持了高维数据的局部性和整体几何结构。但是,由于其只使用了类内信息,导致异类数据点间的结构不够明显,在低维嵌入中会出现异类重构误差小于同类重构误差的情况,从而影响后续的分类能力。在 DAG-ONPP 中,每个样本寻找同类和异类的近邻点,从而建立同类邻接图和异类邻接图。在保证同类局部重构误差尽量小的前提下,使得异类点重构误差更加明显,从而平衡类内与类间的结构关系,这可以有效地提高分类能力。

另外,当样本数量小于每个数据点的维数时,与 NPE 类似的许多算法常常会受到奇异问题的影响。由于 DAG-ONPP 在求解广义特征问题时无需计算矩阵的逆,因此 DAG-ONPP 更加高效和稳定。尽管监督的 ONPP 在计算过程中也无需计算矩阵的逆,但是文献[9]指出在执行监督的 OPNN 算法之前要进行一次 PCA 降维,否则其分类能力会明显下降,因此与监督的 ONPP 相比,DAG-ONPP 更加稳定。

4 实验结果与分析

在 4 个人脸库上用 DAG-ONPP 算法进行了大量的实

验,4个人脸库分别是 Yale 库、ORL 库、YaleB 库和 PIE 库。同时,将本文方法与 PCA,LPP,NPE,MFA 和监督的 ONPP 算法进行对比分析。所有降维后的测试数据用线性回归分类器(LRC)^[13]进行分类。

4.1 线性回归分类器

LRC 利用训练集中每类样本对测试样本的重构残差进行分类,LRC 的主要步骤在算法 2 中给出。

算法 2 LRC

输入:训练集 $X_i \in \mathbb{R}^{q \times p_i}, i=1,2,\dots,N$,测试样本 $y \in \mathbb{R}^{q \times 1}$

输出: y 的类别 $\text{identity}(y)$

1. 求出每类样本对 y 的重构系数 $\hat{\beta}_i \in \mathbb{R}^{p_i}$

$$\hat{\beta}_i = (X_i^T X_i)^{-1} X_i^T y, i=1,2,\dots,N$$

2. 对每一个 $\hat{\beta}_i$, 计算 $y_i, \hat{y}_i = X_i \hat{\beta}_i, i=1,2,\dots,N$

3. 计算残差 $d_i(y) = \|y - \hat{y}_i\|, i=1,2,\dots,N$

4. $\text{identity}(y) = \arg \min d_i(y), i=1,2,\dots,N$

4.2 Yale 库

Yale 人脸数据库^[14]中包含 15 个人,每个人有 11 幅灰度图像,每幅图像的大小为 92×112 像素。Yale 库中人脸的表情、姿态、光照条件均有不同程度的变化,在实验中对所有图像均根据眼睛坐标旋转、剪切、缩放到大小为 32×32 像素的图像,未作其他任何处理,图 1 显示了预处理后 Yale 库中的图像示例。实验中取每类人脸的 5 幅图像作为训练样本,其余的作为测试样本。重复 30 次实验,实验结果的平均值和相关参数记录在表 1 中。图 2 展示了识别率随子空间维度的变化情况。



图 1 Yale 库中的部分样本

表 1 Yale 库中最优识别率的对比

Method	K1	K2	Dimension	Recognition/%
PCA	—	—	80	63.78±1.61
NPE	3	—	32	52.67±2.23
LPP	3	—	30	55.11±1.67
MFA	3	5	25	78.44±0.88
ONPP	—	—	40	77.56±0.83
DAG-ONPP	3	40	53	83.11±0.73




图 2 Yale 库中识别率随维度的变化曲线

4.3 ORL 库

ORL 人脸数据库^[15]由 400 幅图像组成,共 40 名志愿者。均在姿态、表情和面部饰物等变化的条件下对每名志愿者采集 10 幅大小为 92×112 像素的图像。在实验中,所有图像均根据眼睛坐标旋转、剪切、缩放到大小为 32×32 像素的图像,

未作其他任何处理,图 3 示出了预处理后 ORL 库中的图像示例。实验中对每类人脸取 6 幅图像作为训练样本,其余的作为测试样本。重复 30 次实验,实验结果的平均值和相关参数记录在表 2 中。图 4 示出了识别率随子空间维度的变化情况。



图 3 ORL 库中的部分样本

表 2 ORL 库中最优识别率的对比

Method	K1	K2	Dimension	Recognition/%
PCA	—	—	110	95.63±0.51
NPE	3	—	115	91.25±0.96
LPP	3	—	94	90.94±0.62
MFA	5	20	80	97.19±0.78
ONPP	—	—	130	97.81±0.83
DAG-ONPP	3	100	100	98.75±0.67




图 4 ORL 库中识别率随维度的变化曲线

4.4 Extended YaleB 库

Extended Yale B 人脸数据库^[14]包含 38 个人,每幅图像具有不同的光照变化,每人有 64 幅图像。在实验中,所有图像均根据眼睛坐标旋转、剪切、缩放到大小为 32×32 像素的图像,未作其他任何处理。图 5 示出了预处理后的图像示例。实验中对每类人脸取 5 幅图像作为训练样本,其余的作为测试样本。重复 30 次实验,实验结果的平均值和相关参数如表 3 所列。图 6 示出了识别率随子空间维度的变化情况。



图 5 YaleB 库中的部分样本

表 3 YaleB 库中最优识别率的对比

Method	K1	K2	Dimension	Recognition/%
PCA	—	—	130	69.90±1.32
NPE	3	—	81	63.73±1.57
LPP	3	—	94	62.27±1.22
MFA	3	25	60	77.77±0.90
ONPP	—	—	52	77.81±1.16
DAG-ONPP	3	111	133	80.35±1.26




图 6 YaleB 库中识别率随维度的变化曲线

4.5 PIE 库

PIE 人脸数据^[16]包含 68 位志愿者的 41368 张多姿态、光照和表情的面部图像,其中的姿态和光照变化图像也是在严格的条件下采集的,每幅图片大小为 92×112 像素。在实验中,所有图像均根据眼睛坐标旋转、剪切、缩放到大为 32×32 像素的图像,未作其他任何处理。图 7 示出了预处理后 PIE 库中的图像示例。实验中对每类人取 170 幅图片作为实验数据,对每个人脸取 5 幅图像作为训练样本,其余的作为测试样本。重复 30 次实验,实验结果的平均值和相关参数如表 4 所列。图 8 示出了识别率随子空间维度的变化情况。



图 7 PIE 库中的一些样本

表 4 PIE 库中最优识别率的对比

Method	K1	K2	Dimension	Recognition/%
PCA	—	—	223	51.18±0.82
NPE	3	—	135	53.33±0.77
LPP	3	—	133	53.35±1.02
MFA	5	20	63	70.97±0.60
ONPP	—	—	65	73.32±0.91
DAG-ONPP	3	200	252	78.15±0.88




图 8 PIE 库中识别率随维度的变化曲线

4.6 实验结果与分析

从表 1—表 4 以及图 2、图 4、图 6、图 8 可以看出,DAG-ONPP 的分类能力比 PCA,NPE,LPP,MFA 和监督的 ONPP 更出色,这说明判别信息和几何结构对分类都很重要;在 DAG-ONPP 和 ONPP 的比较中可以看出类间信息对分类有重要的作用,因此如何平衡类内与类间信息对之后的分类效果也有较大的影响。

结束语 图嵌入算法在模式识别中是一种有效的降维技术。本文提出了一种新的图嵌入算法 DAG-ONPP,其能够在高维空间中学习出一个较好的低维嵌入子空间,并且能有效运用于分类任务中。DAG-ONPP 通过构造两个邻接图来保持类内和类间的局部结构,平衡了类内与类间的关系,在保证同类局部重构误差尽量小的前提下,使得异类点重构误差更加明显。因此,DAG-ONPP 可以有效地保持样本数据的局部结构,并且能为这些样本找到一个较好的投影矩阵。在 4 个人脸数据库上(Yale,ORL,YaleB,PIE)的实验结果表明,相比于其他同类算法,DAG-ONPP 的表现最出色。

参考文献

[1] HAMMER B, BIEHL M, BUNTE K, et al. A general frame-

work for dimensionality reduction for large data sets [M]// Advances in Self-Organizing Maps. Springer Berlin Heidelberg, 2011:277-287.

[2] DUDA R O, HART P E, STORK D G. Pattern classification [M]. John Wiley & Sons, 2012.

[3] MARTÍNEZ A M, KAK A C. PCA versus LDA [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(2): 228-233.

[4] NIYOGI X. Locality preserving projections[M]// Neural Information Processing Systems. MIT, 2004.

[5] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.

[6] HE X, CAI D, YAN S, et al. Neighborhood preserving embedding[C]// Tenth IEEE International Conference on Computer Vision, 2005 (ICCV 2005). IEEE, 2005: 1208-1213.

[7] YAN S, XU D, ZHANG B, et al. Graph embedding and extensions: a general framework for dimensionality reduction [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51.

[8] WONG W K, ZHAO H T. Supervised optimal locality preserving projection[J]. Pattern Recognition, 2012, 45(1): 186-197.

[9] OKIOPOULOU E, SAAD Y. Orthogonal neighborhood preserving projections: A projection-based dimensionality reduction technique[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(12): 2143-2156.

[10] ZHAO H, SUN S, JIANG Z, et al. Local structure based supervised feature extraction[J]. Pattern Recognition, 2006, 39(8): 1546-1550.

[11] BENGIO Y, PAIEMENT J F, VINCENT P, et al. Out-of-sample extensions for lle, isomap, mds, eigenmaps, and spectral clustering[C]// International Conference on Neural Information Processing Systems. MIT Press, 2003: 177-184.

[12] GOLUB G H, VAN LOAN C F. Matrix computations [J]. Mathematical Gazette, 1996, 47(5 Series II): 392-396.

[13] NASEEM I, TOGNERI R, BENAMOUN M. Linear regression for face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106-2112.

[14] GEORGHIADES A. Yale face database[OL]. <http://cvc.yale.edu/projects/yalefaces/yalefa>.

[15] SAMARIA F S, HARTER A. Parameterisation of a stochastic model for human face identification[C]// Proceedings of the Second IEEE Workshop on Applications of Computer Vision, 1994: 138-142.

[16] SIM T, BAKER S, BSAT M. The CMU pose, illumination, and expression (PIE) database[C]// Fifth IEEE International Conference on Automatic Face and Gesture Recognition, 2002. IEEE, 2002: 46-51.

[17] HAIFENG L, TAO J, KESHU Z. Efficient and robust feature extraction by maximum margin criterion[J]. IEEE Transactions on Neural Networks, 2006, 17(1): 157-165.