

## 正交及不相关边界邻域保持嵌入的人脸识别

陈达遥\*, 陈秀宏

(江南大学 数字媒体学院, 江苏 无锡 214122)

(\* 通信作者电子邮箱 chenda80@126.com)

**摘要:**邻域保持嵌入(NPE)算法本质上仍是一种无监督方法,并没有有效利用已有的类别信息提高分类效率。为此提出两种有监督流形学习方法:正交边界邻域保持嵌入(OMNPE)和不相关边界邻域保持嵌入(UMNPE)。首先构造类内和类间邻接图,并定义类内和类间重构误差;然后分别在正交和不相关约束条件下寻找最小化类内重构误差同时最大化类间重构误差的投影向量;将训练样本和测试样本分别投影到低维子空间中,再利用最近邻分类器进行分类识别。在 ORL 和 Yale 人脸库上的实验结果表明,与线性判别分析(LDA)、边界 Fisher 分析(MFA)等子空间人脸识别算法相比,所提算法的平均识别率提高了 0.5%~3%,验证了算法的有效性。

**关键词:**降维;流形学习;人脸识别;邻域保持嵌入;正交;不相关

**中图分类号:** TP391.413 **文献标志码:** A

### Face recognition based on orthogonal and uncorrelated marginal neighborhood preserving embedding

CHEN Dayao\*, CHEN Xiuhong

(School of Digital Media, Jiangnan University, Wuxi Jiangsu 214122, China)

**Abstract:** Neighborhood Preserving Embedding (NPE) is still an unsupervised method in nature, and it does not take advantage of the existing classification information to improve the classification efficiency. Therefore, two supervised manifold learning methods named Orthogonal Marginal Neighborhood Preserving Embedding (OMNPE) and Uncorrelated Marginal Neighborhood Preserving Embedding (UMNPE) were proposed. Both methods firstly constructed within-class graph and between-class graph and defined within-class reconstructive error and between-class reconstructive error. Then, OMNPE and UMNPE sought to find a projection that simultaneously minimized the within-class reconstructive error and maximized the between-class reconstructive error, under the orthogonal and uncorrelated constraint conditions, respectively. The training samples and testing samples were projected onto low-dimensional subspace respectively. Finally, the nearest neighbor classifier was used for classification. Extensive experiments in ORL and Yale face databases illustrate that the proposed algorithms outperform those of subspace face recognition algorithms with average recognition rate by 0.5%~3%, such as Linear Discriminant Analysis (LDA), Marginal Fisher Analysis (MFA), which proves the effectiveness of the proposed algorithms.

**Key words:** dimensionality reduction; manifold learning; face recognition; Neighborhood Preserving Embedding (NPE); orthogonal; uncorrelated

## 0 引言

在过去几十年里,人脸识别技术得到了很大的发展,特征提取是人脸识别的关键步骤,其主要目的是降维。较为经典的算法有主成分分析(Principal Component Analysis, PCA)<sup>[1]</sup>和线性判别分析(Linear Discriminant Analysis, LDA)<sup>[2]</sup>。这两种算法都假设数据集处于欧氏空间中。而有研究表明,很多复杂对象处于某个流形子空间中<sup>[3-5]</sup>,在这种情况下,PCA 和 LDA 将很可能失效。

基于流形学习方法的人脸识别技术是近年来人脸识别领域中重要的研究成果。目前,比较有代表性的非线性流形学习算法包括:等距映射(Isometric Mapping, ISOMAP)<sup>[3]</sup>、局部线性嵌入(Locally Linear Embedding, LLE)<sup>[4]</sup>、拉普拉斯特征映射(Laplacian Eigenmap, LE)<sup>[5]</sup>等。由于流形学习方法缺乏明晰的投影矩阵从而对新数据点难以处理,因此,He 等<sup>[6]</sup>提

出了 LLE 的线性近似算法——邻域保持嵌入(Neighborhood Preserving Embedding, NPE),它能有效地保持原始数据的局部特性和处理新数据点。但与 PCA 不同,NPE 得到的低维特征是统计相关的<sup>[7-8]</sup>且投影矩阵不具正交性,从而导致所提取的特征信息重叠且不能保持原始高维空间中的测度结构;其次,由于 NPE 缺少类判别信息,故其分类性能偏弱;再者,人脸识别中的小样本问题会使得 NPE 算法存在病态的奇异问题。文献[9]考虑到类别信息,提出了一种有监督邻域保持嵌入(Supervised Neighborhood Preserving Projections, SNPE)算法,但仍存在以上缺点。文献[10]提出了一种正交邻域保持投影(Orthogonal Neighborhood Preserving Projections, ONPP)法,一定程度上提高了 NPE 算法的识别性能,但该方法只考虑了类内判别信息,而未考虑类间判别信息,分类性能仍然偏弱。Yan 等<sup>[11]</sup>利用图嵌入(Graph Embedding)提出了一种最大化类内数据和类外数据“边界(margin)”的边界 Fisher 分析

收稿日期:2013-05-08;修回日期:2013-07-14。

基金项目:中央高校基本科研业务费专项资金资助项目(JUSRP211A70);国家自然科学基金资助项目(61373055)。

作者简介:陈达遥(1988-),男,湖南益阳人,硕士研究生,主要研究方向:人工智能、模式识别; 陈秀宏(1964-),男,江苏泰兴人,教授,博士,主要研究方向:数字图像处理、人脸识别。

法(Marginal Fisher Analysis, MFA)。为避免 MFA 算法所面临的小样本问题,王勇等<sup>[12]</sup>提出了基于最大间距 MFA 的鉴别分析。文献[13]进行了相似的研究,并把相应算法称为最大边界投影(Maximum Margin Projection, MMP)。

基于图嵌入统一框架<sup>[11]</sup>,提出了两种新的流形学习方法,分别称为正交边界邻域保持嵌入(Orthogonal Marginal Neighborhood Preserving Embedding, OMNPE)与不相关边界邻域保持嵌入(Uncorrelated Marginal Neighborhood Preserving Embedding, UMNPE)。在原始 NPE 算法基础上,首先构造类内邻接图和类间邻接图,然后在目标函数中引入类内重构误差和类间重构误差来保留几何和判别结构,最后通过对投影向量添加正交及不相关约束得到正交及不相关边界邻域保持嵌入算法。在 ORL 和 Yale 人脸库上进行实验,以验证算法的有效性。

## 1 邻域保持嵌入算法

NPE<sup>[6]</sup>是一种无监督的线性降维算法,其目标是保持数据流形的局部邻域结构。设给定训练样本数据集为  $X = \{x_1, x_2, \dots, x_n\}$ ,  $x_i \in \mathbf{R}^m$ ,  $n$  为训练样本个数,  $m$  为训练样本的维数。对于任意的样本点  $x_i$ , 通过投影矩阵  $A \in \mathbf{R}^{m \times d}$  进行投影后为  $y_i$ , 即  $y_i = A^T x_i$ , 其中  $d$  为特征空间维数。邻域保持嵌入算法的思想是解以下最小化问题:

$$\min \sum_{i=1}^n \left\| y_i - \sum_{j=1}^n s_{ij} y_j \right\|^2 \quad (1)$$

其中  $S$  为相似度矩阵,元素  $s_{ij}$  代表第  $i$  个数据与第  $j$  个数据的相似度:当  $x_j$  不是  $x_i$  的  $k$  近邻(或  $\varepsilon$ -近邻)时,  $s_{ij} = 0$ ; 其他的  $s_{ij}$  可通过解以下优化问题得到:

$$\begin{aligned} \min \sum_{i=1}^n \left\| x_i - \sum_{j=1}^n s_{ij} x_j \right\|^2 \\ \text{s. t. } \sum_{j=1}^n s_{ij} = 1 \end{aligned} \quad (2)$$

这是一个约束最小二乘问题,文献[4]给出了详细的求解。对式(1)加上约束条件  $A^T X X^T A = I$ , 再对其进行化简得到:

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

其中:  $H = (I - S)^T(I - S)$ ,  $I$  为  $d$  阶单位阵。该问题可转化为求解如下广义特征方程:

$$X H X^T a = \lambda X X^T a \quad (4)$$

于是,投影矩阵  $A$  由式(4)的后  $d$  个最小非零特征值所对应的特征向量构成,从而通过变换  $y_i = A^T x_i$  把样本集  $X = \{x_1, x_2, \dots, x_n\}$  中的每个样本投影到一个低维空间  $\mathbf{R}^d$  ( $d \ll m$ ) 中。

## 2 正交及不相关边界邻域保持嵌入算法

NPE 是一种基于流形学习的邻域保持嵌入算法,它能较好地保持数据流形的局部特性,但由于缺少类别信息,分类性能偏弱。正交及不相关边界邻域保持嵌入算法使用类标签信息,构造类内邻接图和类间邻接图,寻找使类内重构误差最小而类间重构误差最大的投影向量。

为发现数据流形的几何和判别结构,构造如下类内邻接图  $G^w$ : 如果  $x_j$  是  $x_i$  的类内  $k_1$  近邻,则在  $G^w$  中  $x_i$  到  $x_j$  间存在一

条有向边。这里,与 NPE 构图方法不同的是,类内近邻点是指与该样本点同类的近邻点,而 NPE 则是在整个数据集中搜索近邻点。设  $W$  为与  $G^w$  相对应的类内重构权值阵: 如果  $x_j$  不是  $x_i$  的类内  $k_1$  近邻,则  $w_{ij} = 0$ ; 其他的  $w_{ij}$  可通过解以下最优化问题得到:

$$\begin{aligned} \min \sum_{i=1}^n \left\| x_i - \sum_{j=1}^n w_{ij} x_j \right\|^2 \\ \text{s. t. } \sum_{j=1}^n w_{ij} = 1 \end{aligned} \quad (5)$$

为保留数据流形的局部结构,使同一类的近邻点投影到低维空间后也是近邻的,对类内重构误差最小化得以下问题:

$$\min \sum_{i=1}^n \left\| y_i - \sum_{j=1}^n w_{ij} y_j \right\|^2 \quad (6)$$

类似地,构造如下类间邻接图  $G^b$ : 如果  $x_j$  是  $x_i$  的类间  $k_2$  近邻,则在  $G^b$  中  $x_i$  到  $x_j$  间存在一条有向边。这里,类间近邻点是指与该样本点不同类的近邻点。设  $B$  为与  $G^b$  相对应的类间重构权值阵: 如果  $x_j$  不是  $x_i$  的类间  $k_2$  近邻,则  $b_{ij} = 0$ , 其他  $b_{ij}$  可通过解以下最优化问题得到:

$$\begin{aligned} \min \sum_{i=1}^n \left\| x_i - \sum_{j=1}^n b_{ij} x_j \right\|^2 \\ \text{s. t. } \sum_{j=1}^n b_{ij} = 1 \end{aligned} \quad (7)$$

为使不同类间的近邻点投影到低维空间后相距较远,对类间重构误差最大化得以下问题:

$$\max \sum_{i=1}^n \left\| y_i - \sum_{j=1}^n b_{ij} y_j \right\|^2 \quad (8)$$

根据 Yan 等<sup>[11]</sup>提出的图嵌入框架思想,类内邻接图  $G^w$  是一种“内蕴图”(Intrinsic Graph),而类间邻接图  $G^b$  是一种“惩罚图”(Penalty Graph)。

通过简单的代数运算,对式(6)和式(8)进行化简得到:

$$\min \text{tr}(A^T X M^w X^T A) \quad (9)$$

$$\max \text{tr}(A^T X M^b X^T A) \quad (10)$$

其中  $M^w = (I - W)^T(I - W)$ ,  $M^b = (I - B)^T(I - B)$  都为实对称矩阵。最小化问题(9)可使同一类内的近邻点在嵌入的流形上的距离尽可能小,而最大化问题(10)则可使异类间的近邻点在嵌入的流形上的距离尽可能大。为使类内重构误差最小的同时最大化类间重构误差,由多目标优化理论得如下问题:

$$\max \text{tr}(A^T X M X^T A) \quad (11)$$

其中  $M = \mu M^b - (1 - \mu) M^w$ ,  $\mu$  为权重参数且满足  $0 < \mu < 1$ 。

为求解问题(11),添加以下两种常用的约束条件:

1) 正交归一化条件:

$$A^T A = I \quad (12)$$

2) 不相关归一化条件:

$$A^T S_i A = I \quad (13)$$

条件(12)使投影矩阵  $A$  的列向量正交,这不仅能保持原始高维空间中的测度结构和消除所提取特征之间的线性相关性,而且在求解过程中无须对矩阵进行求逆;条件(13)称为不相关的,满足该条件的投影向量坐标之间具有二阶统计不相关性,这里

$$S_i = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T = \frac{1}{n} X(I - \frac{ee^T}{n}) X^T \quad (14)$$

为样本的协方差矩阵,  $\bar{x}$  为样本均值,  $e$  元素全为 1 的  $n$  维列向量。

在条件(12)或(13)下解最大化问题(11),可转化为求解如下广义特征方程:

$$XMX^T a = \lambda Ca \quad (15)$$

显然当  $C = I$  时,对应正交归一化条件(12),所得到的方法称为正交边界邻域保持嵌入(OMNPE);当  $C = S_i$  时,对应不相关归一化条件(13),所得到的方法称为不相关边界邻域保持嵌入(UMNPE)。取式(15)的前  $d$  个最大非零特征值所对应的特征向量组成最优投影矩阵  $A = [a_1, a_2, \dots, a_d]$ 。

当  $C = S_i$  时,由于小样本问题,  $C$  可能为奇异的。为克服  $C$  的奇异性问题并能进行高效的计算,先用 PCA 把原始数据投影到子空间(相应的投影矩阵为  $A_{pca}$ ),再用 OMNPE 算法(相应的投影矩阵为  $A_{omnpe}$ )或 UMNPE 算法(相应的投影矩阵为  $A_{umnpe}$ )进行降维,则总的变换矩阵  $A$  可表示为  $A = A_{pca} A_{omnpe}$  或  $A = A_{pca} A_{umnpe}$ 。

### 3 实验与结果分析

为验证 OMNPE 和 UMNPE 算法的有效性,分别在 ORL、Yale 人脸库上进行仿真实验,并将 OMNPE 和 UMNPE 算法与经典的 PCA 以及新近提出的不相关判别等度规映射(Unrelated Discriminant Isometric Projection, UDIsoP)<sup>[8]</sup>、SNPE、MFA 和 LDA 算法进行比较。为克服奇异性问题和进行高效的计算,在执行 OMNPE、UMNPE、UDIsoP、SNPE、MFA 和 LDA 等算法之前都对原数据进行一次 PCA 降维,然后在降维后的子空间中执行以上各算法。

#### 3.1 人脸库

1) Yale 人脸库 (<http://cvc.yale.edu/projects/yalefaces/yalefaces.html>) 是人脸识别研究中常用的数据库之一, Yale 人脸库包含 15 个人,每人 11 幅包括光照方向(左、右和正面)、眼睛、表情变化(正常、愉快、悲伤、困乏、惊讶和眨眼)共 165 幅灰度图像。

2) ORL 人脸库 (<http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>) 包含 40 个人的 400 幅图像,每个人有 10 幅不同的图像。它们是在不同时间拍摄的;人的面部表情和面部细节有着不同程度的变化(比如眼睛睁或闭、笑或严肃、戴或不戴眼镜);人脸姿态也有相当程度的变化,深度旋转或平面旋转可达  $20^\circ$ , 人脸的尺度也有多达 10% 的变化。

实验中 Yale 人脸库和 ORL 人脸库的示例图像如图 1 所示。这里采用了文献[14]中的预处理方法对原图像进行预处理,即把每幅图像裁剪为  $32 \times 32$  大小的灰度图像,并将像素值归一化到 0 到 1 的范围。在 OMNPE、UMNPE、UDIsoP、SNPE 和 MFA 的 PCA 阶段保留 100% 的能量。在 Fisherface (PCA + LDA) 算法的 PCA 阶段提取的主成分小于等于  $n - c$ , LDA 算法提取的特征维数小于等于  $c - 1$ ,  $c$  为训练样本的类别数,  $n$  为训练样本个数。最后,采用最近欧氏距离分类器分类。

#### 3.2 实验结果

##### 3.2.1 参数 $k_1$ 、 $\mu$ 及 $k_2$ 对平均识别率的影响

实验时, OMNPE 和 UMNPE 算法中  $k_1$ , 通常情况下可取  $k_1 = t - 1$ ,  $t$  为每类训练样本的个数, 每个样本与同类样本中的  $t - 1$  个样本相连接。



(a) Yale人脸库



(b) ORL人脸库

图 1 部分人脸图像

为确定 OMNPE 和 UMNPE 算法中最佳参数  $\mu$  和  $k_2$ , 在 ORL 人脸库中, 每人分别随机选取 3, 4, 5 幅图片进行训练, 然后用剩余的图片进行测试, 分别随机地独立进行 50 次实验。OMNPE 和 UMNPE 算法在不同  $\mu$  下平均识别率的变化情况如表 1~2 所示。

表 1 OMNPE 算法中不同  $\mu$  下平均识别率比较 %

训练集	$\mu$						
	0.01	0.05	0.1	0.3	0.5	0.7	0.9
3Train	91.1	91.3	91.4	91.4	90.2	87.0	80.6
4Train	94.7	94.9	95.1	94.4	93.3	90.5	85.7
5Train	96.9	97.0	96.9	96.0	94.7	92.1	88.7

表 2 UMNPE 算法中不同  $\mu$  下平均识别率比较 %

训练集	$\mu$						
	$1E-4$	$1E-3$	$5E-3$	$1E-2$	0.1	0.3	0.5
3Train	92.4	92.4	92.4	92.4	92.3	89.5	85.3
4Train	95.4	95.4	95.3	95.3	92.5	88.7	86.6
5Train	97.0	97.0	96.9	96.7	93.4	90.7	89.8

由表 1~2 可知, 当  $\mu$  取值较小时可以获得更高识别率, OMNPE 算法当  $\mu$  在 0.05 附近时识别率趋于稳定, UMNPE 算法当  $\mu$  在 0.005 附近时识别率趋于稳定。

图 2 给出了 OMNPE 和 UMNPE 算法在不同  $k_2$  下平均识别率的变化情况。





图 2 不同  $k_2$  下平均识别率比较

可知, OMNPE 算法识别率对  $k_2$  的取值不敏感, 通常情况下可取  $k_2 = k_1$ 。UMNPE 算法中  $k_2$  取值较大时能获得更高识

别率,当大于一定的数值后识别率趋于稳定。

在 Yale 数据集上进行实验,能得到相似的实验结果。

3.2.2 识别性能分析

在 ORL 人脸库中,每人分别随机选取 2,3,4,5,6,7,8 幅图片进行训练,剩余的图片作为测试,分别随机地独立进行 50 次实验;在数据集 Yale 上也进行类似的实验。图 3~4 显示了每人分别随机选取 2,5 个训练样本,5 种方法的平均识别率和降维后特征空间维数  $d$  的关系。

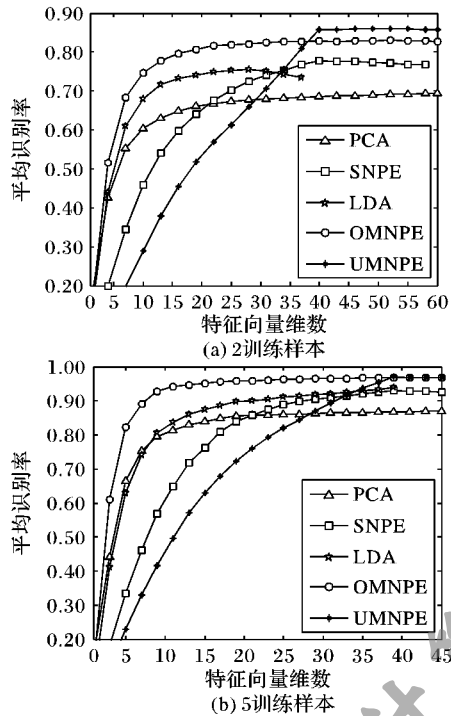


图 3 在 ORL 人脸库实验中的平均识别率和相应维数

由图 3~4 可知,PCA 算法的识别性能最低,因为它是非监督学习算法,没有使用类标签信息。LDA 是有监督学习算

法,虽然使用了标签信息,但提取的特征维数较少及忽视了流形的局部结构,识别率偏低。当每人随机选取 2 幅图片进行训练时,LDA 算法最佳识别率明显低于 SNPE、OMNPE 和 UMNPE 算法。OMNPE 和 UMNPE 算法的识别性能是最优的,算法的最佳识别率高于 PCA、LDA 及 SNPE 算法的最佳识别率,在特征维数分别达到 39 和 14 维以后,识别率整体上趋于稳定。

为消除 OMNPE 和 UMNPE 识别结果的偶然性,进一步验证各方法的识别性能,表 3~4 记录了以上实验所取得的平均识别率和标准差,其中各情形下的最佳平均识别率和标准差用粗体标出。




图 4 在 Yale 人脸库实验中的平均识别率和相应维数

表 3 在 ORL 人脸库实验中的平均识别率和标准差比较 %

方法	训练样本个数						
	2	3	4	5	6	7	8
OMNPE	83.1±3.1	91.2±2.0	95.0±1.5	<b>97.0±1.3</b>	97.6±1.2	<b>98.1±1.4</b>	<b>98.7±1.2</b>
UMNPE	<b>86.1±2.8</b>	<b>92.4±1.7</b>	<b>95.4±1.6</b>	<b>97.0±1.3</b>	<b>97.7±1.4</b>	98.0±1.3	98.6±1.2
SNPE	77.8±3.0	86.0±2.3	90.5±2.0	93.0±1.6	94.3±2.1	95.5±1.7	96.5±1.8
UDIsop	76.1±3.0	84.6±2.4	89.2±2.1	92.1±1.6	93.6±2.3	94.6±2.1	96.0±2.0
LDA	75.5±3.4	86.3±2.4	91.2±2.0	94.0±1.5	95.2±1.8	95.5±2.0	96.9±1.7
MFA	80.0±3.4	90.4±2.0	94.2±1.4	96.0±1.5	96.8±1.7	97.4±1.6	98.2±1.3
PCA	70.4±3.2	78.9±2.5	84.5±2.1	88.1±2.2	90.4±2.2	92.5±2.7	94.2±2.7

表 4 在 Yale 人脸库实验中的平均识别率和标准差比较 %

方法	训练样本个数						
	2	3	4	5	6	7	8
OMNPE	55.5±4.3	67.5±3.7	74.2±4.3	78.6±3.7	<b>82.9±3.7</b>	<b>83.6±3.5</b>	85.8±4.4
UMNPE	<b>57.4±4.6</b>	<b>69.1±3.6</b>	<b>75.2±4.3</b>	<b>79.7±3.4</b>	82.6±3.5	83.1±3.9	<b>86.3±4.3</b>
SNPE	53.9±4.1	66.1±4.5	71.2±4.7	75.5±3.8	79.1±3.9	80.5±4.0	82.0±4.9
UDIsop	54.6±4.3	65.3±3.8	70.9±4.4	75.2±3.3	78.6±3.7	79.5±4.7	81.4±4.8
LDA	43.8±3.7	60.7±4.2	68.6±4.8	74.1±4.4	77.6±4.1	79.4±4.4	81.2±4.2
MFA	53.3±4.6	67.2±4.1	73.1±4.7	78.0±3.9	81.0±3.6	81.9±4.5	84.4±4.6
PCA	46.0±3.3	51.8±3.7	54.9±3.8	58.1±4.1	60.7±4.1	61.9±4.7	64.5±5.4

由表 3~4 可知,随着训练样本个数的增加,各方法识别率增加,有监督方法优于无监督方法。在 ORL 人脸库上,基于局部的 SNPE 和 UDIsop 算法识别率低于基于全局的 LDA

算法,说明在 ORL 人脸库中全局结构信息比局部结构信息更重要。而在 Yale 人脸库上却恰好相反,SNPE 算法和 UDIsop 算法识别率优于 LDA 算法,局部结构信息比全局结构信息更

重要。由此可知,局部结构信息和全局结构信息重要性依赖于确定的数据集。不同于 LDA, MFA 没有假设所有类都是高斯分布的,而是将同类样本中邻近的样本拉近,同时让异类样本间邻近的样本远离,识别率优于 LDA、SNPE、UDIsop、PCA。OMNPE 和 UMNPE 算法通过引入类内、类间重构误差和对投影向量添加正交和不相关约束条件,保留了几何和判别结构,有效消除了投影向量之间的信息冗余和增强了算法的分类鉴别能力,提取鉴别信息的能力高于其他方法,且整体上相对稳定。即使在训练样本个数较少的情况下,OMNPE 和 UMNPE 算法也有比较好的表现且 UMNPE 算法平均识别率优于 OMNPE 算法平均识别率。当训练样本个数较多时,UMNPE 算法和 OMNPE 算法取得相近的识别结果。

#### 4 结语

本文在 NPE 算法的基础上提出了正交及不相关边界邻域保持嵌入的人脸识别算法。首先利用类内近邻和类间近邻构造类内邻接图和类间邻接图,然后定义类内重构误差和类间重构误差来保留原始数据的几何和判别结构,最后分别在正交及不相关约束条件下最小化类内重构误差和最大化类间重构误差。在 Yale 和 ORL 人脸库上的实验结果表明,当姿态、光照、表情等发生变化时,以上算法都具有良好的识别性能,从而说明该算法既能有效地降低如人脸图像之类的高维数据的维数并消除信息冗余,又能保持数据的拓扑结构,提高鉴别能力。

注意到本文讨论的都是线性降维方法,引入核技术将 OMNPE 和 UMNPE 算法推广到非线性降维领域是值得进一步研究的工作。另外,基于稀疏表示<sup>[15]</sup>的 OMNPE 和 UMNPE 算法以及探讨 OMNPE 和 UMNPE 算法之间的关系也是本研究的后续工作。

#### 参考文献:

- [1] TURK M A, PENTLAND A P. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71–86.
- [2] BELHUMEUR P N, HESPAHIA 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.
- [3] TENENBAUM J B, da SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500): 2319–2323.
- [4] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323–2326.
- [5] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6): 1373–1396.
- [6] HE X, CAI D, YAN S, *et al.* Neighborhood preserving embedding [C]// *Proceedings of the 10th International Conference of Computer Vision*. Washington, DC: IEEE Computer Society, 2005: 1208–1213.
- [7] HUANG H, LIU J, FENG H, *et al.* Ear recognition based on uncorrelated local Fisher discriminant analysis [J]. *Neurocomputing*, 2011, 74(17): 3103–3113.
- [8] GE B, SHAO Y, SHU Y. Uncorrelated discriminant isometric projection for face recognition [C]// *Proceedings of the 3th International Conference on Information Computing and Applications*. Berlin: Springer, 2012: 138–145.
- [9] ZENG X, LUO S. A supervised subspace learning algorithm: supervised neighborhood preserving embedding [C]// *Proceedings of the Third International Conference on Advanced Data Mining and Applications*. Berlin: Springer, 2007: 81–88.
- [10] KOKIOPOULOU E, SAAD Y. Orthogonal neighborhood preserving projections [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(12): 2143–2156.
- [11] 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.
- [12] 王勇, 卢桂馥. 基于最大间距 MFA 的鉴别分析 [J]. *光电工程*, 2011, 38(2): 102–107.
- [13] HE X, CAI D, HAN J. Learning a maximum margin subspace for image retrieval [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2008, 20(2): 189–201.
- [14] SHU X, GAO Y, LU H. Efficient linear discriminant analysis with locality preserving for face recognition [J]. *Pattern Recognition*, 2012, 45(5): 1892–1898.
- [15] GUO L, ZHENG Z, JIA J, *et al.* Sparse discriminating neighborhood preserving embedding [C]// *Proceedings of the 4th International Conference on Artificial Intelligence and Computational Intelligence*. Berlin: Springer, 2012: 721–728.
- [8] 夏英, 刘晓凤. 与时机判定相结合的关联规则增量更新算法 [J]. *重庆邮电大学学报: 自然科学版*, 2013, 25(1): 111–115.
- [9] 智慧来, 智东杰. 关系粒度的概念格增量维护与关联规则更新 [J]. *计算机科学*, 2013, 40(4): 256–258.
- [10] LE B, TRAN C T, HONG T P, *et al.* A space-time trade off for FUFPT-trees maintenance [C]// *Proceedings of the 5th Asian Conference on Intelligent Information and Database Systems*. Berlin: Springer, 2013: 206–214.
- [11] NG V, CHAN S, LAU D, *et al.* Incremental mining for temporal association rules for crime pattern discoveries [C]// *Proceedings of the Eighteenth Conference on Australasian Database*. Darlinghurst: Australian Computer Society, 2007: 123–132.
- [12] HE J, HE Q, QIAN F, *et al.* Incremental maintenance of discovered spatial colocation patterns [C]// *Proceedings of the 2008 IEEE International Conference on Data Mining Workshops*. Piscataway: IEEE Press, 2008: 399–407.
- [13] YU L, BIAN F. An incremental data mining method for spatial association rule in GIS based fireproof system [C]// *Proceedings of the 2007 International Conference on Wireless Communications, Networking and Mobile Computing*. Piscataway: IEEE Press, 2007: 5978–5981.
- [14] 马荣华, 蒲英霞, 马小东. GIS 空间关联模式发现 [M]. 北京: 科学出版社, 2007.
- [15] 李中元. 基于空间缓冲矩阵的空间关联知识提取与表达 [D]. 武汉: 武汉大学, 2012.
- [16] 李建松. 地理信息系统原理 [M]. 武汉: 武汉大学出版社, 2006.
- [17] 董林, 舒红, 牛宵. 利用叠置分析和面积计算实现空间关联规则挖掘 [J]. *武汉大学学报: 信息科学版*, 2013, 38(1): 95–99.
- [18] AGRAWAL R, SRIKANT R. Fast algorithm for mining association rules [C]// *Proceedings of the 20th International Conference on Very Large Data Bases*. San Francisco: Morgan Kaufmann, 1994: 487–499.
- [19] HAN J, KAMBEER K, PEI J. Data mining: concept and techniques [M]. 3rd ed. San Francisco: Morgan Kaufmann, 2011.

(上接第 3051 页)