

doi:10.11835/j.issn.1000-582X.2017.03.010

# 多邻域保持嵌入的人脸识别方法

刘嘉敏,袁佳成,彭玲,刘亦哲,罗甫林

(重庆大学 光电工程学院,重庆 400044)

**摘要:**现有流形学习算法在学习人脸数据时,假设所有数据点位于单一低维嵌入流形之上,当数据点实际分布在不同的流形上时,单流形假设就会影响数据真实空间结构。为此提出一种基于多邻域保持嵌入(multiple neighborhood preserving embedding, M-NPE)的学习算法来发现不同类别数据在不同维度的低维嵌入空间中分布的多流形结构。首先,单独学习不同类别数据的流形,得到反映其本质特征的流形;再通过遗传算法搜索每个流形的最优维数;最后依据最小重构误差分类器对样本分类。在 Extended Yale B 和 CMU PIE 这 2 个大型人脸库上实验结果验证了该算法的有效性。

**关键词:**本质维数;人脸识别;多流形学习;重构误差;多邻域保持嵌入

**中图分类号:**TP391.4

**文献标志码:**A

**文章编号:**1000-582X(2017)03-088-07

## Multiple neighborhood preserving embedding algorithm for face recognition

LIU Jiamin, YUAN Jiacheng, PENG Ling, LIU Yizhe, LUO Fulin

(College of Optoelectronic Engineering, Chongqing University, Chongqing 400044, P. R. China)

**Abstract:** Traditional manifold learning methods assume that face data may reside on one single manifold, but data from different classes may reside on different manifolds of possible different intrinsic dimensions, thus the assumption of single manifold may affect the learning of the actual distribution relationship of the image data in the high dimensional space. In this paper, a multiple manifold learning algorithm based on multiple neighborhood preserving embedding(M-NPE) was proposed to find a low-dimensional embedding for data lying on multiple manifolds. First, the manifolds of different classes were learned by NPE for each class separately, and the low dimensionality coordinates and mapping matrix of the data was obtained. The genetic algorithm (GA) was then employed to obtain the nearly optimal dimensionality of each face manifold from the classification viewpoint. Classification was performed under a criterion that is based on the minimum reconstruction error on manifolds. The experimental results on both Extended Yale B and CMU PIE large-scale face database verified the effectiveness of the algorithm.

**Keywords:** intrinsic dimensionality; face recognition; multi-manifold learning; reconstruction error; multiple neighborhood preserving embedding

人脸识别是当今极具研究价值和应用价值的一门生物特征识别技术,目前主要应用于门禁系统、支付系统、网络应用等领域<sup>[1]</sup>。人脸识别的关键是从人脸图像中提取出最具鉴别力的特征<sup>[2]</sup>。

**收稿日期:**2016-09-14

**基金项目:**中央高校基本科研业务费资助项目(1061120131207,CDJXS12120001);重庆市研究生科研创新资助项目(CYS14028)。

Supported by the Fundamental Research Funds for the Central Universities(1061120131207,CDJXS12120001) and Graduate Student Research Innovation Project in Chongqing(YS14028).

**作者简介:**刘嘉敏(1971-),重庆大学副教授,博士,主要从事信息获取与技术,图像处理等方向研究,(E-mail)2834297334@qq.com。

流形学习算法的核心就是找到高维数据的低维嵌入流形,实现维数约减<sup>[3]</sup>。发现低维嵌入流形的几个较著名的非线性流形学习算法有:局部线性嵌入(locally linear embedding, LLE)<sup>[4]</sup>、等距映射(Isomap)<sup>[5]</sup>和拉普拉斯特征映射(laplacian eigenmap, LE)<sup>[6]</sup>。这些算法和谱图理论紧密结合,它们虽然能够得到高维数据的低维表达,但这些算法都是通过隐式映射的方法将数据从高维空间映射到低维空间,这样就面临新的数据集较难处理的问题。所以,He 等<sup>[7-10]</sup>相继提出了包括邻域保持嵌入(neighborhood preserving embedding, NPE)、局部保留投影(locality preserving projection, LPP)等的线性流形学习算法,这些算法能够有效保持样本之间的局部近邻结构,还能将人脸数据映射到一个反映其本质特征的流形结构上。

上述流形学习算法,都是将不同类别的数据映射到一个统一的低维嵌入流形之上。而实际数据点可能位于不同的流形上<sup>[11-13]</sup>,这样会影响数据之间真实空间分布的描述。多流形分布问题已被越来越这方面的学者意识到,提出了一些有监督的流形学习算法<sup>[14-16]</sup>,尝试利用样本的类别标签方法来解决多流形分类问题。虽然取得不错的识别效果。但这些算法仍然是在单一的空间或同一个坐标系下来揭示数据的低维流形,由此得到不同类别数据形成的流形,其本质是一个单一流形的子流形,此外这些算法过多地强调辨别性能。由此可知如果对可能具有多个不连续子集的真实数据集采用单一流形假设算法是不能得到最优识别效果的。

在多人脸流形分类框架的基础上,提出了多邻域保持嵌入(multiple neighborhood preserving embedding, M-NPE)算法,根据算法流程,用不同类别的人脸数据表述不同的低维流形,且认为各类数据的本质特征和维数不尽相同。M-NPE 算法的基本流程是:1)使用 NPE 方法分别学习各类人脸数据的低维流形;2)利用遗传算法(GA)优化多个流形在分类意义下的维数,得到最优维数组;3)在多流形上对新人脸样本进行分类,所用分类器是基于最小重构误差分类器。

## 1 多邻域保持嵌入学习算法原理

### 1.1 单流形学习框架

单流形学习框架如图 1 所示,利用 NPE 算法将不同类人脸数据映射到一个统一的低维流形上。

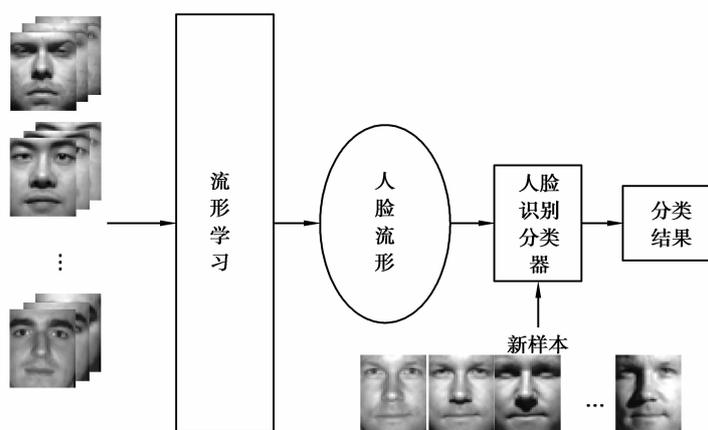


图 1 人脸识别单流形学习框架

Fig.1 The general framework of single-manifold based face recognition methods

### 1.2 多邻域保持嵌入学习算法框架

图 2 为算法的框架。研究算法:假设多类数据处于多个流形之上,这样保持了样本空间的局部几何结构的最优性,也学习到了各类样本的最优邻域及其相应的投影矩阵,嵌入空间的分辨能力也更强。

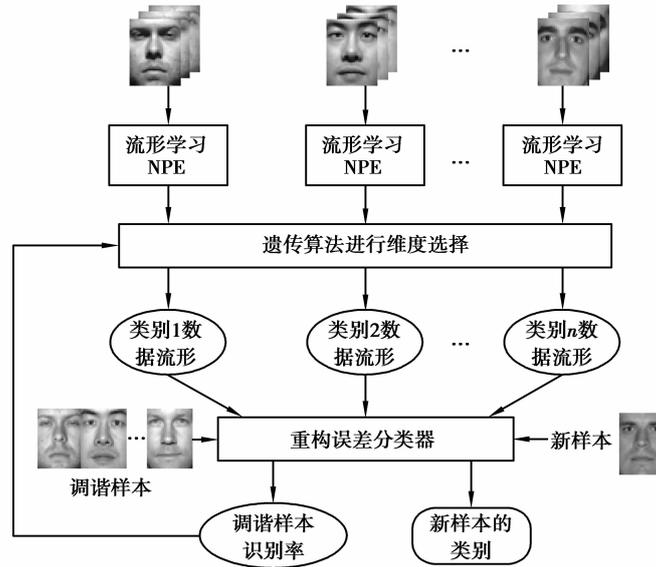


图 2 M-NPE 算法框架

Fig.2 The framework of the proposed multiple NPE based face recognition method

1.3 NPE 算法

NPE 算法的基本思想:任意给定一个样本点集,利用  $k$  近邻线性表述该原始空间中的样本点,并根据最小重构误差准则使得空间中的所有样本点的重构权重系数不变,以保证样本映射到低维空间前后的权重关系不改变。

$X = \{x_1, x_2, \dots, x_N\}, x_i \in R^D$  为高维空间中  $N$  个样本点,则  $x_i \approx \sum_{j \in N(x_i)} \omega_{ij} x_j$ , 其中  $N(x_i)$  表示样本  $x_i$  的邻域,  $\omega_{ij}$  为对应的权值。  $\omega_{ij}$  通过最小化目标函数得到

$$\varphi(W) = \sum_i \| x_i - \sum_j \omega_{ij} x_j \|^2, \tag{1}$$

使服从①若  $x_i$  和  $x_j$  互为邻域点,则  $\omega_{ij} = 0$ ; ②  $\sum_j \omega_{ij} = 1$ 。

寻一组  $d$  维数据点集,  $Y = \{y_1, y_2, \dots, y_N\} (y_i \in R^d, d \in D), y_i = a^T x_i$ 。  $Y$  和  $X$  具有相同的局部几何结构,则  $a$  可通过最小化目标函数得到

$$\begin{aligned} \varphi(a) &= \sum_i \| y_i - \sum_j \omega_{ij} x_j \|^2 = \\ &= \sum_i \| a^T x_i - \sum_j \omega_{ij} a^T x_j \|^2, \end{aligned} \tag{2}$$

简单的代数变换后,有

$$a = \arg \min_a \frac{a^T X M X^T a}{a^T X X^T a}, \tag{3}$$

其中,  $X = [x_1, x_2, \dots, x_N], M = (I - W)^T (I - W)$ 。

通过 Lagrange 乘数法得到广义特征值

$$X M X^T a = \lambda X X^T a, \tag{4}$$

令式(4)的解依据其对应特征值的升序排序为  $a_1, a_2, \dots, a_d$ , 即  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_d$ , 令  $A = [a_1, a_2, \dots, a_d] \in R^{m \times d}$ , 则嵌入为  $x_i \rightarrow y_i = A^T x_i$ 。

1.4 多流形维度选择

在维数选择步骤中直接显式地将分类准确率作为目标函数进行优化。决定所有子流形的维数是一个联合优化问题,采用穷举法获取最优维数的效率低,而遗传算法(GA)具有较强的全局非线性优化能力,因此采用遗传算法对维数进行优化。

设 $\{d_1, d_2, \dots, d_N\}$ 分别为数据集 $\{X_1, X_2, \dots, X_N\}$ 的低维流形空间维数。调谐样本集 $T_u$ 是由各流形中一部分有类别标签的数据构成,它们是随机的,对各流形维数组合进行浮点数编码,且适应度用于度量群体各个体在有助优化的过程中的优良程度,因此依据选择的流形学习算法对 $T_u$ 分类的识别率构建遗传算法的适应度函数

$$f(d_1, d_2, \dots, d_N) = \frac{1}{|T_u|} \sum_{x_i \in T_u} L(l(x_i), \arg \min_k \text{error}_k(x_i)), \quad (5)$$

其中, $|T_u|$ 表示 $T_u$ 中样本的个数; $l(x_i)$ 是数据点 $x_i$ 的类别标签, $x_i$ 的类别标签 $\arg \min_k \text{error}_k(x_i)$ 通过重构误差法得到, $L(l_1, l_2)$ 为1表示类别标签 $l_1$ 与 $l_2$ 相同,否则为0。

首先根据经验设置若干组维数作为初始种群,在迭代中,依适应度函数来评判优劣性,对进化出的下一代重复搜索,得到最优的一组多流形维数。

### 1.5 重构误差分类器

对于某一特定流形的数据点,其低维表示与其他流形上 $K$ 近邻点之间的重构误差大于该低维表示与原流形的重构误差。因此,可以将新样本在多个流形上的重构误差值作为判断其所属类别的依据。

假设新样本数据 $x_0$ 低维映射坐标 $y_0^k = \mathbf{A}_k^T x_0, k=1, 2, \dots, N, N^k$ 为通过 $k$ -NN或 $\epsilon$ 邻域方法得到的 $y_0^k$ 在每个流形上的邻域,则 $x_0$ 在第 $k$ 个流形上的重构误差可表示为

$$\text{error}_k(x_0) = \min_{y_i^k} \left\| y_0^k - \sum_{y_i^k \in N^k} w_i^k y_i^k \right\|^2, \quad (6)$$

约束条件为 $\sum_i w_i^k = 1$ 。计算出新样本在低维流形上的重构误差,可以根据重构误差最小化准则函数判断出新样本所属的流形

$$\hat{l}(x_0) = \arg \min_{k \in \{1, 2, \dots, N\}} \text{error}_k(x_0), \quad (7)$$

其中 $l(x_0)$ 表示 $x_0$ 所属流形的类别标签。

## 2 实验及分析

选择在大型的人脸数据库 Extended Yale B<sup>[17]</sup>和 CMU PIE<sup>[18]</sup>上实验并以识别率为指标来评估 M-NPE 算法的性能。同时对比主成分分析(principal component analysis, PCA)、线性鉴别分析(linear discriminant analysis, LDA)、局部线性嵌入(LLE)、局部保持投影(LPP)、邻域保持嵌入(NPE)和有监督邻域保持嵌入(supervised neighborhood preserving embedding, SNPE)<sup>[14]</sup>等算法的实验结果。

### 2.1 Extended Yale B

Extended Yale B人脸数据库收集了38个人分别在64种不同的光照条件下采集图像。在研究中,选取了2432幅人脸图像作为实验数据集,来学习每类人脸数据所包含的流形结构。图3所示为Extended Yale B人脸库中所收入部分人脸图像,其光照强度和表情都各不相同,将人脸图像基于眼睛位置对齐,剪裁出固定像素大小为 $32 \times 32$ 的脸部区域。

随机选取该数据库中每个个体所有64幅图像中的32幅作为训练样本集。最后的识别率取10次实验的平均值。实验结果如图4所示,表1列出了各类方法在最高维数80时的最高总体识别率。在M-NPE算法中,各个流形的维数是确定。因此,为了便于比较各算法的识别效果M-NPE算法的分类识别率用一条直线来表示。此数据库求得的最优维数为30。此外LDA算法降维最高只能降到类别数-1维,因此其在实验中维度与其他算法不同,之后的实验亦此原因。

### 2.2 CMU PIE

PIE人脸库包含68个人在不同姿态、光照、表情下的41368幅图像。取数据库中每人的80幅包含光照和表情变化的近似正面姿态的人脸图像作为实验样本集;将人脸图像基于眼睛位置对齐,剪裁出固定像素大小为 $32 \times 32$ 的脸部区域。图5所示为该数据库其中一人经剪裁后的部分人脸。

在该数据库中随机选取每人40幅图像作为训练样本集。对于多流形试验,由于其流形具有一组最优维



图 3 Extended Yale B 样本集中的一些样本

Fig.3 Some images from Extended Yale B database

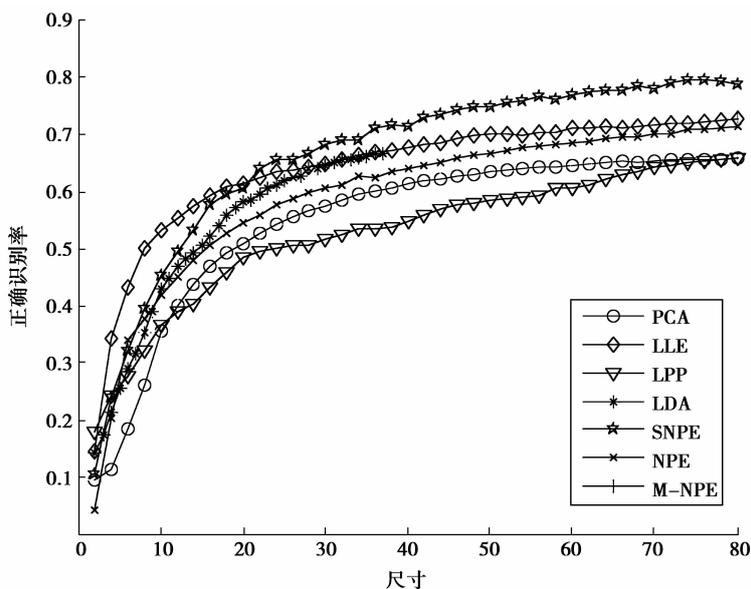


图 4 Extended Yale B 库上识别结果

Fig.4 Recognition results on Extended Yale B database



图 5 CMU PIE 样本集中某一个人的一些样本

Fig.5 Some images of one person from CMU PIE database

数,因此 M-NPE 的实验结果可用一条直线表示。此实验的最优维数为 27。取 10 次实验的平均值作为算法的最后识别结果。实验结果如图 6 所示。表 1 也列出了各类方法在最高维数 100 时的最高识别率情况。

表 1 各算法的最高总体识别率(平均值±标准差(%))

Table 1 The highest overall classification accuracy of different algorithms (mean ± std(%))

算法	PCA	LPP	LLE	LDA	NPE	SNPE	M-NPE
Yale B	65.56±0.01	65.67±0.02	72.37±0.02	66.40±0.01	71.06±0.02	79.32±0.01	88.10±0.01
PIE	75.54±0.01	68.61±0.01	64.26±0.02	77.70±0.01	79.88±0.02	85.22±0.01	93.40±0.01

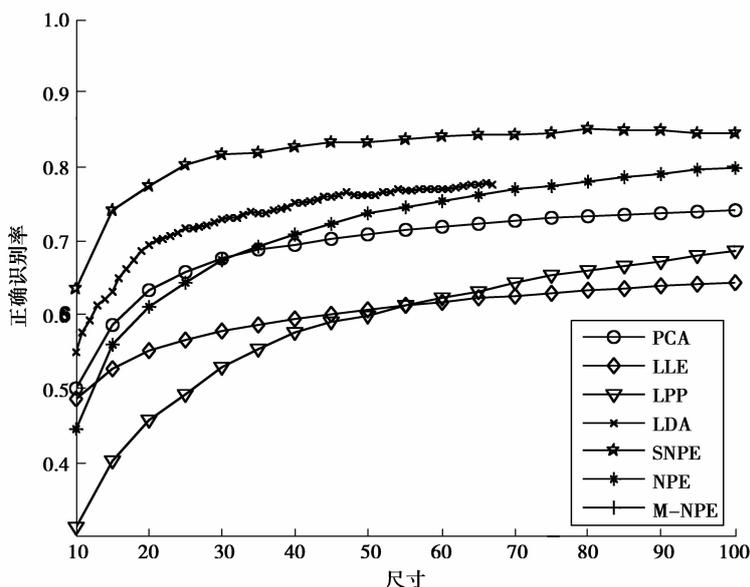


图 6 CMU PIE 库上识别结果

Fig.6 Recognition results on CMU PIE database

实验主要在 Extended Yale B 和 CMU PIE 上进行。在 2 个数据库的多流形实验中,将每类人脸数据随机取出 50% 的样本作为训练样本,用来学习相对应的低维流形;剩余数据中随机选择 30% 作为测试样本用来搜索多流形的最优维数组合;通过除去训练样本的 50% 的样本作为新样本集的方法来测试 M-NPE 算法的识别性能。其中数据样本的标注由人工来完成。基于单流形假设算法在 2 次实验中都是训练样本和测试样本各占一半,对全部训练样本学习出一个统一的低维流形,测试样本用来测试各算法的识别效果。取 10 次重复实验的平均值作为各个算法的识别结果。

### 2.3 实验结果分析

以上的实验结果清楚地证明所提出的基于多邻域保持嵌入的分类方法对于人脸识别的有效性和稳定性,它较基于单流形的方法得到了更好的分类结果。这也证明了在人脸识别中,单流形假设并不能保证得到最优的分类准确率。相反,多流形假设更加合理。研究提出的基于多邻域保持嵌入的分类方法的核心思想是学习特定类的流形,即为每一个类别学习一个流形。当使用基于单流形的方法时,所有的样本均通过一个通用的映射投影到同一个流形上,而提出的基于多邻域保持嵌入的方法中,对每一个类别的训练样本集学习一个流形及其相应的投影矩阵。M-NPE 算法分类学习得到每类数据最优低维流形。而单一流形降维后样本空间的低维流形结构扭曲嵌入空间的局部表征能力降低。因此,对足够的训练样本进行学习时,较之于单一流形学习的方法基于 M-NPE 方法的识别率有显著提高。

M-NPE 算法的计算复杂度较高。在第一步训练过程中,学习多个流形需要花费更多的计算时间。从图 2 所示的算法流程图中,可知,这个问题可以通过并行计算来克服。即对不同类别的数据同时学习。而训练算法中最耗时的部分是基于 GA 的最优维数的求解过程。离线搜索可使这个问题得到有效解决。

## 3 结 语

多流形假设给数据分类提供了一种新的思路,直接将数据按照类别标记进行划分,认为每一个类对应于一个流形,对数据本身的分布情况没有深入探讨。当数据本身没有标记时,即在非监督情况下,如何通过多流形聚类算法得到多流形的分布模型,是今后值得探讨的问题。

### 参考文献:

- [1] 黄璞,唐振民.鉴别的局部中值保持投影及其在人脸识别中的应用[J]. 计算机辅助设计与图形学学报,2012,24(11): 1420-1425.

- HUHANG Pu, TANG Zhenmin. Discriminant local median preserving projections with its application to face recognition[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2012, 24(11): 1420-1425. (in Chinese)
- [2] 王万良, 邱虹, 黄琼芳, 等. 核判别随机近邻嵌入分析方法[J]. *计算机辅助设计与图形学学报*, 2014, 26(4): 623-631  
WANG Wanling, QIU Hong, HUANG Qiongfang, et al. Kernel-Based discriminative stochastic neighbor embedding analysis[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2014, 26(4): 623-631. (in Chinese)
- [3] Seung H S, Lee D D. The manifold ways of perception[J]. *Science*, 2000, 290(5500): 2268-2269.
- [4] Roweis S T, Saul K L. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, 290: 2323-2326.
- [5] Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. *Science*, 2000, 290: 2319-2323.
- [6] Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering[C]// *Proceedings of Neural Information Processing Systems*, Vancouver: MIT, 2001, 14: 585-591.
- [7] Niyogi P. Locality preserving projections[C]// *Proceedings of Neural Information Processing Systems*, Vancouver: MIT, 2004, 16: 153.
- [8] He X, Yan S, Hu Y, et al. Learning a locality preserving subspace for visual recognition[C]// *Proceedings of Computer Vision*, 2003. *Proceedings of 19th IEEE International Conference on [S. L.]*. IEEE, 2003: 385-392.
- [9] He X, Yan S, Hu Y, et al. Face recognition using Laplacian faces[J]. *Pattern Analysis and Machine Intelligence*, IEEE *Transactions on*, 2005, 27(3): 328-340.
- [10] He X, Cai D, Yan S, et al. Neighborhood preserving embedding[C]// *Proceedings of Computer Vision*, 2005. *ICCV 2005, Tenth IEEE International Conference on [S. L.]*. IEEE, 2005, 2: 1208-1213.
- [11] Xiao R, Zhao Q, Zhang D, et al. Facial expression recognition on multiple manifolds[J]. *Pattern Recognition*, 2011, 44(1): 107-116.
- [12] Xiao R, Zhao Q, Zhang D, et al. Data classification on multiple manifolds[C]// *Proceedings of Pattern Recognition (ICPR)*, 2010 *20th International Conference on [S. L.]*. IEEE, 2010: 3898-3901.
- [13] 王立志, 黄鸿, 冯海亮. 多线性局部与全局保持嵌入在高光谱遥感影像分类中的应用[J]. *计算机辅助设计与图形学学报*, 2012, 24(6): 780-786.  
WANG Lizhi, HUANG Hong, FENG Hailiang. Multi-linear local and global preserving embedding and its application in hyperspectral remote sensing image classification[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2012, 24(6): 780-786. (in Chinese)
- [14] Gui J, Sun Z, Jia W, et al. Discriminant sparse neighborhood preserving embedding for face recognition[J]. *Pattern Recognition*, 2012, 45(8): 2884-2893.
- [15] De Ridder D, Kouropteva O, et al. Supervised locally linear embedding[C]// *Artificial Neural Networks and Neural Information Processing- ICANN/ICONIP 2003*. Springer Berlin: IEEE, 2003: 333-341.
- [16] Yan S C, 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.
- [17] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, 15(6): 1373-1396.
- [18] Saul L K, Weinberger K Q, Ham J H, et al. Spectral methods for dimensionality reduction[J]. *Semisupervised Learning*, 2006: 293-308.