

# 应用于人脸识别的改进局部保持投影算法

张悦<sup>1</sup>, 刘德山<sup>1</sup>, 王姗姗<sup>1</sup>, 闫德勤<sup>1</sup>, 楚永贺<sup>2</sup>

(1. 辽宁师范大学 计算机与信息技术学院, 辽宁 大连 116081;

2. 大连理工大学 电子信息与电气工程学部, 辽宁 大连 116024)

**摘要:** 局部保持投影算法 (locality preserving projections, LPP) 作为降维算法, 在机器学习和模式识别中有着广泛应用; 在识别分类中, 为了更好地利用类别信息, 在保持样本点的局部特征外, 有效地从多维数据中提取出低维的人脸图像信息并提高人脸图像的识别率和识别速度, 使分类达到一定优化, 基于 LPP 算法结合流形学习思想, 通过构造一种吸引向量的方法提出一种改进的局部保持投影算法 (reformation locality preserve projections, RLPP); 将数据集利用极端学习机分类器进行分类后, 在标准人脸数据库上的进行试验, 实验结果证明, 改进后算法的识别率优于 LPP 算法、局部保持平均邻域边际最大化算法和鲁棒线性降维算法, 具有较强的泛化能力和较高的识别率。

**关键词:** 局部保持投影; 类别信息; 人脸识别; 降维

## Improved Locality Preserving Projections for Face Recognition

Zhang Yue<sup>1</sup>, Liu Deshan<sup>1</sup>, Wang Shanshan<sup>1</sup>, Yan Deqin<sup>1</sup>, Chu Yonghe<sup>2</sup>

(1. College of Computer and Information Technology, Liaoning Normal University, Dalian 116081, China;

2. Department of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116024, China)

**Abstract:** As a dimensionality reduction algorithm, Locality Preserving Projections (LPP) is widely used in machine learning and pattern recognition. In the recognition classification, in order to make better use of the category information, in addition to maintaining the local features of the sample points, the low-dimensional face image information is effectively extracted from the high-dimensional data and the recognition rate and recognition speed of the face image are improved. The classification is optimized to a certain extent. Based on the LPP algorithm combined with the manifold learning idea, a reformation locality preserve projections algorithm (RLPP) is proposed by constructing an attractive vector. After the data set is classified by the extreme learning machine classifier, the experiment is carried out on the standard face database. The experimental results show that the improved algorithm has better recognition rate than the LPP algorithm, the local-preserving average neighborhood margin maximization algorithm and the robustness linear dimensionality reduction algorithm, and has strong generalization ability and high recognition rate.

**Keywords:** locality preserving projections; category information; face recognition; dimensionality reduction

## 0 引言

目前在国内外研究人脸识别技术的方法有很多, 常用的方法有: 基于三维数据的人脸识别方法、基于连接机制的人脸识别方法、基于代数特征的人脸识别方法以及基于几何特征的人脸识别方法。基于特征方法的目标就是寻找人脸或人脸的部件可能具有在各种条件下都不会改变的特征或属性 (例如: 形状、肤色、纹理、边缘信息等), 并利

用这些特征来定位信息。然而这类方法使用局限性很高, 对人脸姿态、面部表情、旋转缩放都不敏感, 只有在特定的环境下或动作幅度差别很大才非常有效且检测速度较高。由于人脸部件的提取通常都借助于边缘算子, 因此, 这类方法对图像质量要求较高, 对光照和背景等同样有较高的要求, 因为光照、噪音、阴影都极有可能破坏人脸部件的边缘, 从而影响算法的有效性<sup>[1]</sup>。可是在安保、门禁、身份鉴别、人口检测等实际应用中, 人脸识别的数据集常常拥有样本量少、维数高等特点。因而通常使用神经网络等算法结合维数约简技术提高分类率。

近年来大批学者在机器学习领域展开了深入的探究, 其中机器学习的核心理论流形学习也迅速地发展成熟起来。流形学习先是构造一个数据邻接图来描述数据分布或几何结构, 然后寻找一个最佳投影方向或映射来有效地维护结构。基于此研究人员提出了基于流形学习的线性或非线性的降维算法, 如拉普拉斯特征映射 (laplacian eigenmaps,

收稿日期: 2019-03-11; 修回日期: 2019-04-03。

基金项目: 辽宁省自然科学基金项目 (20170540574)。

作者简介: 张悦 (1993-), 女, 辽宁大连人, 硕士研究生, 主要从事模式识别、机器学习方向的研究。

刘德山 (1970-), 男, 辽宁辽阳人, 硕士生导师, 教授, 主要从事数据挖掘、智能信息处理的研究。

闫德勤 (1964-), 男, 教授, 硕士生导师, 教授, 主要从事模式识别、机器学习方向的研究。

LE)<sup>[2]</sup>, 局部线性嵌入 (locally linear embedding, LLE)<sup>[3]</sup>, 局部保持投影 (locality preserving projection, LPP)<sup>[4]</sup> 和邻域保持嵌入 (neighborhood preserving embedding, NPE)<sup>[5]</sup>, 甚至包括模式识别经典的线性降维算法——主成分分析法 (principal component analysis, PCA)<sup>[6]</sup> 和线性判别分析 (linear discriminant analysis, LDA)<sup>[7]</sup>, 即 Fisher 线性判别 (fisher linear discriminant, FLD) 都具有一些共同的特征, 均可以构造流形上样本点的局部邻域结构, 然后用这些局部邻域结构来将样本点全局的映射到一个低维空间。

局部保持投影是 HE 等人<sup>[8]</sup>发现 LE 仅对获取的少数人脸数据点进行定义和运算, 算法的泛化能力比较弱而提出了线性逼近 LE 的一种线性化形式。该算法将 LE 的隐式非线性映射采用合适的手段转换为显式的线性映射来进行表示, 因此新的人脸数据样本可以直接得到低维嵌入空间中的映射点以达到相应的目的。在近年来的特征提取领域里面, 不断涌出了大量优秀的算法, 但是 LPP 算法在人脸识别的领域中还是占有不可或缺的地位, 属于研究人脸识别的算法里面最基础的算法之一。

2008 年, 张志伟等人<sup>[9]</sup>为了增强 LPP 算法对外部因素的抗干扰能力, 提出了一种有监督的局部保持投影算法 (SLPP), 通过对 LPP 子空间进行判别分析, 选择基向量来构造子空间进行识别。2009 年, 支瑞聪等人<sup>[10]</sup>提出了基于线性判别的局部保持投影算法 (DLPP), 将判别分析的思想引入 LPP, 考虑样本间和模式类之间的相邻关系, 从而得到最优投影方向。2010 年, 王国强等人<sup>[11]</sup>提出了图像矩阵判别局部保持投影 (IMDLPP) 的线性降维算法, 利用类间散度约束和类标签信息, 使求解的特征更具判别性。2012 年, 李晓曼等人<sup>[12]</sup>提出了基于改进邻域的局部保持投影 (Improved Locality Preserving Projections, 简称 ILPP) 算法, 采用构造近邻图的方式得到高维数据在低维空间的本质信息。同年, 杨凡等人<sup>[13]</sup>基于 DLPP 算法提出了谱回归判别局部保持投影算法 (SRDLPP) 避免解决稠密矩阵特征分解时带来的高昂内存和时间消耗。2016 年, 王博林等人<sup>[14]</sup>提出了基于流形学习的有监督稀疏排列的局部保持投影算法 (SSLPP) 减少人脸识别的时间复杂度, 方便获取到具有低维人脸图像的特征信息。

## 1 局部保持投影 (LPP)

LPP 算法是 LE 算法的一种线性逼近过程, 避免了 LE 算法无法有效处理测试样本的问题, 提高了算法的泛化能力, 对流形学习中的非线性数据进行处理和分析具有较大的优势。它利用构建空间中各样本对之间的远近亲疏关系方法建立关系映射, 继承了 LE 算法保持空间中原始数据局部邻域关系的优势, 能够进行普通线性学习算法所没有的流形分析和学习, 具有处理速度快, 数据计算简单, 可以获得新样本点的低维投影的独特特性等优势。

设样本  $X = (x_1, x_2, \dots, x_n)$  为原始高维空间数据集,

维数为  $D$ , 来自于高维欧式空间  $R^D$ ,  $Y = (y_1, y_2, \dots, y_n)$  为降维后数据集, 维数为  $d$ , 属于低维空间  $R^d$ 。为了求得最佳的投影方向矩阵  $A$ , 需要在一定的约束条件下最小化下面的目标函数:

$$\min \frac{1}{2} \sum_{i,j} (y_i - y_j)^2 W_{ij} \quad (1)$$

### 1) 计算近邻点

通过使用  $q_0$  近邻或者  $\epsilon$  近邻方法, 找到高维空间中彼此相近的样本点, 构造一个近邻图。距离公式为:

$$d(x_i, x_j) = \|x_i - x_j\| \quad (2)$$

### 2) 选择权重值

$$W_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2/t), & t \text{ 为热核函数, } x_i \text{ 与 } x_j \text{ 近邻} \\ 0, & \text{其他} \end{cases} \quad (3)$$

其中:  $W_{ij}$  为对称关联矩阵, 表示近邻样本点  $i$  和  $j$  之间的相似程度。优先选用近邻或近邻方法检索出高维空间两两接近的样本点, 通过式 (3) 计算近邻点之间的高斯加权重值作为样本间相似性的度量。如果  $x_i$  和  $x_j$  经过映射后相距较远, 则会令对应的  $W_{ij}$  的值也会很小来作为惩罚项进行平衡。

### 3) 计算特征矢量

$$XLX^T a = \lambda DX^T a \quad (4)$$

其中:  $D$  为一个对角矩阵,  $D_{ij} = \sum_{j=1}^n W_{ij}$ ,  $L = D - W$  是拉普拉斯矩阵,  $a$  为特征矢量。

4) 通过式子 (4) 计算广义特征向量求得投影方向  $A = (A_1, A_2, \dots, A_L)$ 。根据它们的特征值大小进行排序,  $0 \leq \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_m$ , 然后通过  $Y = a^T x$  计算出  $Y$ 。

## 2 改进的局部保持投影算法 (RLPP)

LPP 虽然严格地保留了人脸数据样本原始的局部邻域结构, 但却忽略了人脸图像数据的类别信息, 在不同种类样本受到光照、姿态、表情等非可控条件的影响后容易出现类间距离小的数据之间的重叠。为了尽可能地减少外在不可抗拒条件对结果的影响, 改善识别性能, 本文在 LPP 算法基础上选择把类别信息上给出的数据标签具体化, 进而提出了一种改进 LPP 的方法, 称为 RLPP (Reformation Locality Preserve Projections)。首先利用训练样本的类别信息来构造吸引向量, 并将高维样本点绘制到低维数据吸引点的子空间中。

改进的局部保持投影算法构造了数据样本的邻接图矩阵, 通过投影变换将数据样本映射到低维空间, 可以获取数据样本全局的几何结构信息, 亦可较好地反应出样本数据流形结构, 处理速度快, 数据计算简单, 提高算法的泛化能力。RLPP 算法优势体现在: 可以在不破坏局部邻域关系的前提下进行降维, 能提取出原始人脸图像数据的本质特征; 充分利用 LE 算法能够保持原始数据局部邻域关系的优势, 将 LE 算法结合非线性映射等手段转换为显式的线性映射进行改进, 保留人脸图像空间结构并可以较大程度避

免干扰人脸图像识别等许多要素的降维方法,以达到即使对数据进行降维处理后仍能保留数据内部原始非线性状态的目的;重视了人脸图像数据的类别信息,改善类内距离较大类间距离较小的数据点之间不便于区分的问题。RLPP 模型可以表示形式如下:

假设有一组训练样本矩阵  $\mathbf{X} = (x_1, x_2, \dots, x_c) \in R^{m \times n}$ ,  $x_i \in R^m$ , 其中  $M$  是高维空间中训练样本的维数,  $N$  是训练样本的总数,  $C$  是数据样本类别个数。对于每一个训练样本,我们利用其类别信息构造一个吸引向量  $h_i \in R^c$ 。如果  $y_i = c$ , 那么,  $h_i$  样本中的第  $C$  类样本的结果为 1, 其他项样本为零。因此, 属于同一类的训练样本被具有相同的吸引点的矢量汇聚在一起。从而将子空间中的每个样本都能被归类到与它属性相同的吸引向量上。

为了使低维坐标点的几何特征与类别信息进行制约, 我们寻求一个最佳投影矩阵  $\mathbf{V} \in R^{m \times c}$ , 它可以将训练点投影到一个相对低维的特征子空间中。假设  $V$  为所求的投影向量, 那么在子空间样本矩阵可以表示  $y = v^T x$ , 从而  $Y^T = V^T X$ , 即  $Y = (Y_1, Y_2, \dots, Y_c)^T$  是数据集  $X$  的低维表示形式,  $y_i \in \{1, 2, \dots, c\}$ 。

基于 LPP 算法, 引入吸引向量得到下列目标式子:

$$R = R_1 + R_2 = \sum_{ij} (y_i^c - y_j^c)^2 W_{ij}^c + \beta \sum_{i=1}^n (y_i - h_i)^2 \quad (5)$$

式 (5) 中,  $\beta \in [0, +\infty]$  是一个用于平衡类别信息重要性的控制参数。

将式子 (5) 进行推导, 其中左式  $R_1$  结合  $y = v^T x$  优先推导如下:

$$R_1 = \sum_{c=1}^C \sum_{i,j=1}^n (v^T x_i^c - v^T x_j^c)^2 W_{ij}^c = \sum_{c=1}^C \left( \sum_{i=1}^n v^T x_i^c D_{ii}^c (x_i^c)^T v - \sum_{i,j=1}^n v^T x_i^c W_{ij}^c (x_j^c)^T v \right) = V^T X (D - W) X^T V = V^T X L X^T V \quad (6)$$

其中:  $W_{ij}^c$  为重构权重矩阵, 它反应了数据点  $x_i$  的同类邻域中数据点  $x_j$  对  $x_i$  重建的贡献, 构造出对角矩阵  $D_{ii}^c = \sum_j W_{ij}^c$ ,  $L = D - W$  为拉普拉斯矩阵。  $W$  矩阵为构成加权图将原样本本作为顶点并与相邻点连接。对各顶点重要性进行度量是矩阵的作用。  $D_{ii}$  值与数据  $i$  的重要性成正比。

我们定义  $z_i = y_i - h_i$ ,  $Z = (z_1, z_2, z_3, \dots, z_n)$ ,  $H = \begin{bmatrix} h_{11} & h_{12} & \dots & h_{1n} \\ h_{21} & h_{22} & \dots & h_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ h_{n1} & h_{n2} & \dots & h_{nn} \end{bmatrix}$ , 因此  $Z = Y - HY = (I - H)Y$ , 其中  $I = \text{diag}(1, 1, \dots, 1)$ 。

暂时先不考虑控制参数  $\beta$ , 将式 (5) 右式推导如下:

$$R_2 = \sum_{i=1}^n (y_i - h_i)^2 = \sum_{i=1}^n (z_i)^2 = Z^T Z = [(I - H)Y]^T [(I - H)Y] = Y^T (I - H)^T (I - H) Y = Y^T S Y = V^T X S X^T V \quad (7)$$

其中: 吸引矩阵  $H = (h_1, h_2, \dots, h_n) \in R^{c \times n}$ , 设矩阵  $S = (I - H)^T (I - H) Y$ 。

结合式 (6)、(7) 可以将目标式 (5) 最终化简为:

$$R = R_1 + R_2 = \sum_{ij} (y_i^c - y_j^c)^2 W_{ij}^c + \beta \sum_{i=1}^n (y_i - h_i)^2 = V^T X L X^T V - \beta V^T X S X^T V = V^T (L_1 - \beta S_1) V \quad (8)$$

对于式 (8), 对于构造出来的对角矩阵  $L \in R^{m \times n}$ , 实数矩阵  $H \in R^{c \times n}$ ,  $L_1 = X L X^T$ ,  $S_1 = X S X^T$ ,  $\beta \in R^+$  以及  $X \in R^{m \times n}$ , 限制条件为  $V^T X X^T V = 1$ 。

由于  $\beta$  是一个控制参数, 在理论上我们极小化目标参数是只考虑  $V^T X (L - S) X^T V$ , 且矩阵  $L - S$  是对称的, 采用拉格朗日乘子法将目标函数最小化:  $L(V) = V^T (L_1 - S_1) V - \lambda (V^T X X^T V - 1)$ 。令  $\frac{\partial L(V)}{\partial (V)} = 2(L_1 - S_1)V - 2\lambda X X^T V = 0$ , 要使投影矩阵  $V$  达到最优,  $V$  必须满足的条件是  $(L_1 - S_1)V = \lambda X X^T V$ 。求得  $(X X^T)^{-1} (L_1 - S_1)$  的广义特征值为  $\lambda_0, \lambda_1, \dots, \lambda_{d-1}$  (其中  $\lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_{d-1}$ ), 对应的特征量为  $v_0, v_1, \dots, v_{d-1}$ ,  $V = (v_0, v_1, \dots, v_{d-1})$ ,  $A$  为  $D \times d$  维的矩阵, 因此,  $Y_{d \times n} = V_{d \times d}^T \times X_{d \times n}$ 。

### 3 实验结果与分析

为验证 RLPP 效果, 本次实验使用了 3 个著名的基准人脸图像数据库 (Yale 人脸库、Yale B 人脸库和 ORL 人脸库), 并在每组数据库中分别随机选取每类样本点的训练个数与测试样本数, 进而将实验结果与 LPP, LPANMM 和 RAF-GE 算法进行比较得出不同维数下的识别率。本文所有的实验都是在处理器为 Inter (R) Core (TM) i5-3470 3.20 GHz、内存为 4GB 的 64 位操作系统机器上完成, 编辑环境为 matlab2016b。

本文将选用的数据集随机生成的样本点投射到一个二维空间中。在构造相邻图时, LPP、RLPP、LPANMM 和 RAF-GE 四种算法都具有邻域参数  $k$ , 此外, RLPP 还涉及了控制参数  $\beta$ 。控制参数  $\beta$  的取值在理论上对嵌入投影的结果有影响, 可以通过改变控制参数的取值来改善该算法的分类性能。且经多次实验测验, 选取邻域参数  $k=7$  时, 实验效果较为稳定。

在 Yale、ORL 人脸库中本实验随机选取训练个数为  $TN = \{2, 4, 6, 8\}$  的数值, 剩余部分为测试集; 在 Yale B 中随机选择  $TN = \{10, 15, 20, 25\}$  的训练集个数。惩罚参数均为相同数值。RLPP 算法与 LPP 算法, LPANMM 算法<sup>[15]</sup>, RAF-GE 算法<sup>[16]</sup> 在不同维数下的准确率曲线如图 2~4 所示, 数据集描述如表 1 所示, 不同人脸图像的部分训练集如图 1 所示<sup>[17]</sup>。

从图 2 给出的 4 种算法在 Yale 人脸数据集上识别率的对比实验可以看出, 以原始 LPP 算法 (空心点所在折线) 的实验数据折线走势为基础, 实心黑点折线代表的 LPANMM 算法波动幅度很大, 数据不稳定, 倒三角折线代表的 RAF-GE 算法同 LPANMM 算法一样走势不稳定,

表 1 数据集描述

数据集	维数	样本	每类样本数	类别数
Yale	1024	165	11	15
YaleB	1024	2414	55	38
ORL	1024	400	10	40

稳定性能略差一些, 实验结果数据的波动幅度很大, 我们反复多次进行试验后, 实验数据中 LPANMM 算法和 RAF-GE 算法识别率走势结果仍然显示如此。但本文提出的 RLPP 算法的识别率一直最高。

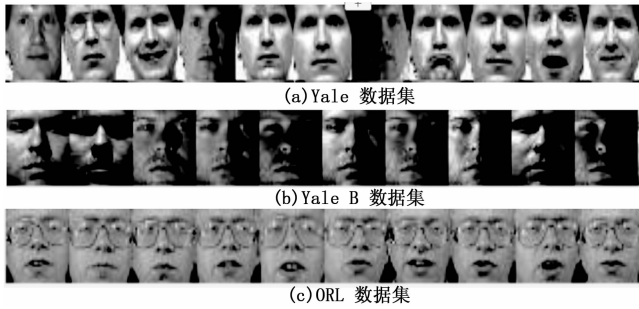


图 1 不同人脸图像的部分训练集

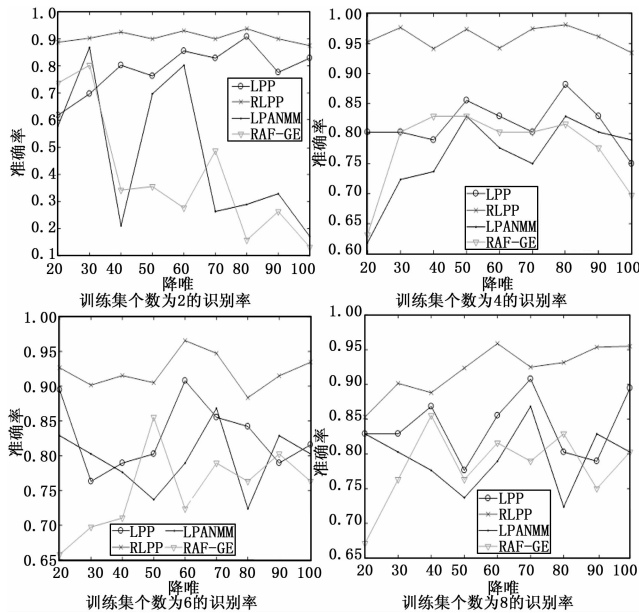


图 2 4 种算法在 Yale 人脸库准确率曲线

表 2 不同降维算法在 Yale 人脸库识别率(平均值±相对误差)%

算法	Yale			
	2 个训练集	4 个训练集	6 个训练集	8 个训练集
LPP	78.65±8.67	81.58±3.84	82.89±4.97	83.92±4.59
RLPP	90.64±2.05	95.98±1.77	92.16±2.50	92.12±3.51
LPANMM	46.78±27.04	76.17±6.56	79.53±4.56	77.49±3.45
RAF-GE	39.47±23.79	77.63±6.74	75.15±6.05	78.22±5.39

从表 2 统计的平均值和相对误差值结果可以看出, 在 Yale 人脸数据集中, 当训练样本个数选取为 2 时, 数据样本的平均识别率从 LPP 的 78.65% 提高到改进后的 90.64%; 当每类训练样本个数选取为 6 时, 数据样本的平均识别率从 LPP 的 82.89% 提高到改进后的 92.16%; 同时 RLPP 算法的相对误差与其他算法相比略低一些, 整个识别率曲线的波动相对不大, 反应出 RLPP 算法在 Yale 人脸数据集里体现出很好的稳定性。

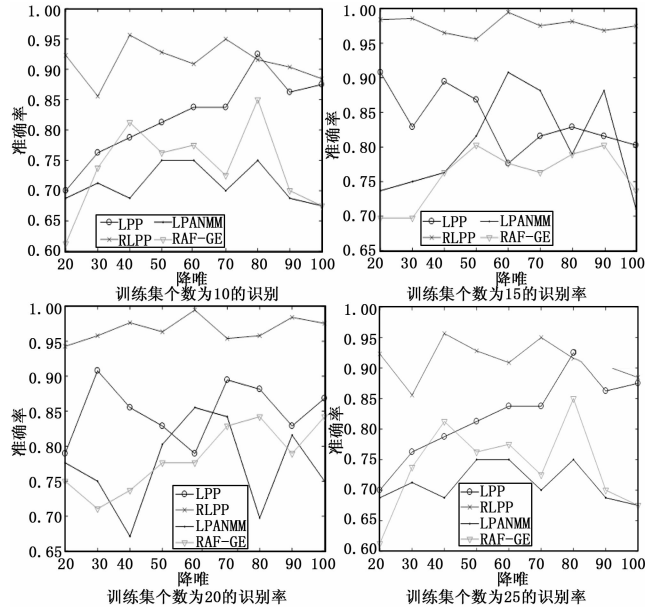


图 3 4 种算法在 YaleB 人脸库准确率曲线

表 3 不同降维算法在 YaleB 人脸库识别率(平均值±相对误差)%

算法	Yale B			
	10 个训练集	15 个训练集	20 个训练集	25 个训练集
LPP	82.22±6.64	83.77±4.36	84.94±4.32	82.02±6.48
RLPP	91.42±3.12	97.62±1.19	96.75±1.64	97.34±1.22
LPANMM	71.11±3.09	80.41±7.16	77.34±6.27	65.90±7.24
RAF-GE	73.89±7.19	75.88±4.06	78.36±4.70	57.35±5.70

由图 3 和表 3 数据分析可知在 Yale B 人脸库中, 4 种算法的准确率曲线中 RLPP 算法的准确率浮动率介于 90%~98% 之间, 比较稳定, 且当训练样本数选取为 8 时, RLPP 算法在 Yale B 人脸库中的平均值最大、相对误差最小, 在本次测试样本中优于其他 3 种算法; 由图 4 和表 4 数据分析可以看出, 在 ORL 人脸库中进行测试时, 不同算法数据差异较大, 准确率曲线波动明显, 整体数据准确率偏低。其中 LPP 算法数据不稳定较明显且当训练样本数据为 2、3、4 时, 识别率处在比较低的水平, 这是由于 LPP 算法针对 ORL 人脸库中部分人脸表情和细节变化, 例如戴或不戴眼镜, 人脸姿态深度旋转和平面旋转一定度数, 人脸尺寸略有变化等检测不敏感。虽然如此, RLPP 的准确率仍在

LPP, LPANMM 和 RAF-GE 三种算法之上, 平均较其他 3 种算法比较为稳定, 根据相对误差数据进行分析显示测试结果更为客观。这是因为 RLPP 算法利用类别信息构造吸引向量, 从而使用矢量来存储特征的测量结果, 进而保留局部邻域结构使实验结果更稳定。

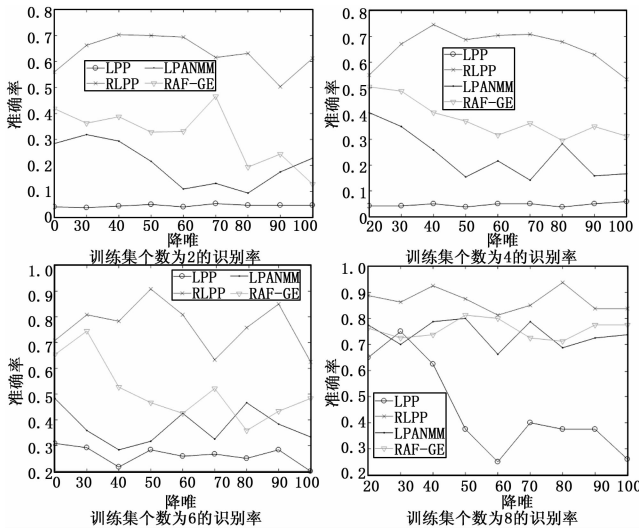


图 4 4 种算法在 ORL 人脸库准确率曲线

表 4 不同降维算法在 ORL 人脸库识别率(平均值±相对误差)%

算法	ORL			
	2 个训练集	4 个训练集	6 个训练集	8 个训练集
LPP	4.63±0.7	5.10±0.81	26.20±3.54	45.11±17.89
LPANMM	23.7±9.41	28.99±10.62	37.50±6.98	74.03±4.99
RAF-GE	37.82±7.46	37.74±8.38	51.26±11.98	75.83±3.54
RLPP	65.65±7.24	65.45±5.58	76.48±9.49	82.50±3.37

#### 4 结束语

本文提出了一种改进的局部保持投影算法, 在识别分类中, 为了更好地利用类别信息, 在保持样本点的局部特征外, 有效地从高维数据中提取出低维的人脸图像信息并提高人脸图像的识别率和识别速度, 使分类达到一定优化, 基于 LPP 算法结合流形学习思想, 通过构造一种吸引向量的方法提出一种改进的局部保持投影算法 RLPP。RLPP 首先建立临界图在高维空间, 然后找到权重邻接图矩阵。最后, RLPP 利用类别信息和投影矩阵进行样本从高维空间到低维空间投影。在标准人脸数据库上的实验结果中可以看到, 改进后算法的识别率优于 LPP 算法、LPANMM 算法和 RAF-GE 算法, 具有较强的泛化能力和较高的识别率, 因而, RLPP 在人脸识别任务中具有优势, 可以提供更好的不同训练次数下的算法效果样本, 是一种行之有效的降维算法。

#### 参考文献:

- [1] 中国安防展览网. 人脸识别技术中基于几何特征的识别方法 [DB/OL]. [http://www.afzhan.com/Tech\\_news/detail/127453.html](http://www.afzhan.com/Tech_news/detail/127453.html), 2015-12-11/2019-3-1.
- [2] Belkin M, Niyogi P. Laplacian Eigenmaps and spectral techniques for embedding and clustering [J]. Advances in Neural Information Processing System, MIT Press, 2002, 14: 585-591.
- [3] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290: 2323-2326.
- [4] He X, Niyogi P. Locality preserving projections [A]. Proceedings of the Conference on Advances in Neural Information Processing Systems [C], 2003.
- [5] He X, Cai D, Yan S, et al. Neighborhood preserving embedding [A]. Proc. IEEE Int'l Conf. Computer Vision [C], 2005: 1208-1213.
- [6] Turk M A, Pentland A P. Face recognition using eigenfaces [A]. IEEE International Conference on Computer Vision and Pattern Recognition (CVPR) [C], 1991.
- [7] Belhumeur P, Hefanpha J, Kriegman D. Eigenface vs. fisherfaces: recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19: 711-72.
- [8] He X, Niyogi P. Locality preserving projections [A]. Proceedings of Advances in Neural Information Processing Systems [C], MA: Cambridge, 2004: 153-160.
- [9] 张志伟, 杨帆, 夏克文, 等. 一种有监督的 LPP 算法及其在人脸识别中的应用 [J]. 电子与信息学报, 2008 (03): 539-541.
- [10] 支瑞聪, 阮秋琦. 基于线性判别局部保留映射的人脸表情识别 [J]. 信号处理, 2009 (02): 233-237.
- [11] 王国强, 石念峰, 欧宗瑛. 基于图像矩阵判别局部保持投影的人脸识别 [J]. 计算机工程与应用, 2010 (16): 191-196.
- [12] 李晓曼, 王靖. 基于类别信息的监督局部保持投影方法 [J]. 计算机应用, 2012 (02): 531-534.
- [13] 杨凡, 张银玲, 牛静. 基于谱回归判别分析的 LPP 算法 [J]. 微型机与应用, 2012 (16): 38-41.
- [14] 王博林, 闫德勤, 楚永贺. 基于稀疏排列的 LPP 和 ELM 的人脸识别 [J]. 微型机与应用, 2016, 35 (23): 42-45.
- [15] Chen X M, Liu W Q, Lai J H, et al. Face recognition via local preserving average neighborhood margin maximization and extreme learning machine [J]. Soft Computing, 2012, 16 (9).
- [16] 冯林, 刘胜蓝, 张晶, 等. 高维数据中鲁棒激活函数的极端学习机及线性降维 [J]. 计算机研究与发展, 2014, 51 (06): 1331-1340.
- [17] 张海英, 闫德勤, 杨伊, 等. 基于流形学习的极端学习机及其在人脸识别中的应用 [J]. 计算机测量与控制, 2016, 24 (12): 158-161.