

# 基于自适应近邻局部保持投影算法的人脸识别

周博, 何宇清, 王建

天津大学电气自动化与信息工程学院, 天津 300072

**摘要** 针对传统的局部保持投影算法(LPP)直接使用数据的原始空间信息导致选取近邻不准确,以及 LPP 算法投影时忽略数据类别信息的问题,提出一种基于自适应近邻局部保持投影的人脸识别方法。该方法在特征提取时利用可变的相似度、近邻信息以及数据类别信息构建目标函数,使得在投影子空间中同类样本尽量紧凑,异类样本尽量远离。通过最小化目标函数自适应优化邻接矩阵与投影矩阵,用优化后的投影矩阵对高维数据进行降维,采用降维后的数据进行人脸分类识别。将该方法应用于扩展 Yale 人脸数据库、CMU-PIE 人脸数据库、MSRA 人脸数据库和 CAS-PEAL 人脸数据库中进行人脸识别,实验结果验证了其有效性。

**关键词** 图像处理; 人脸识别; 局部保持投影; 自适应近邻; 子空间学习

中图分类号 TP391 文献标识码 A

doi: 10.3788/LOP55.031010

## Face Recognition Based on Adaptive Neighborhood Locality Preserving Projection Algorithm

Zhou Bo, He Yuqing, Wang Jian

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

**Abstract** Traditional locality preserving projection (LPP) algorithm directly uses the spatial information of original data, which leads to inaccurately select neighborhood, and ignores data categories information of projection of LPP algorithm. To solve these problems, a face recognition method is proposed based on adaptive neighborhood LPP. In the feature extraction, the objective function is constructed based on the variable similarity, neighborhood information, and data categories information, so that the same class samples are close and different class samples are far away from each other in projected subspace. Adjacency matrix and projection matrix are adaptably optimized by minimizing objective function. Optimized projection matrix is used to reduce the dimension of high-dimensional face data, and low-dimensional data is used to classify and recognize face samples. The experimental results on Yale B, PIE, MSRA and CAS-PEAL databases validate the effectiveness of the proposed algorithm.

**Key words** image processing; face recognition; locality preserving projection; adaptive neighborhood; subspace learning

**OCIS codes** 100.3008; 100.2960; 100.5010

## 1 引言

人脸识别<sup>[1-2]</sup>是一种利用脸部特征信息进行身份识别的生物识别技术<sup>[3]</sup>,其广泛应用于金融、军事、司法、公共安全、教育以及医疗等领域<sup>[4]</sup>。人脸图像数据具有维数高的特点,如何通过特征提取降

低数据维数,并保持其内在特征是人脸识别的研究重点。子空间分析方法<sup>[5-6]</sup>是人脸识别领域的研究热点,其具有计算代价小、描述性强及可分性强等特点<sup>[7]</sup>。典型的子空间分析方法包括主成分分析(PCA)<sup>[8-9]</sup>、线性判别分析(LDA)<sup>[10]</sup>等方法。然而,PCA 算法和 LDA 算法都是全局线性方法,无法很

收稿日期: 2017-09-13; 收到修改稿日期: 2017-09-26

基金项目: 国家自然科学基金(61472274)

作者简介: 周博(1993—),男,硕士研究生,主要从事模式识别与机器学习方面的研究。E-mail: zhoubo@tju.edu.cn

导师简介: 何宇清(1973—),男,博士,讲师,主要从事图像超分辨率重建方面的研究。

E-mail: heyuqing@tju.edu.cn(通信联系人)

好地保持局部信息。

为了更好地提取人脸数据的局部特征, He 等<sup>[11-12]</sup>提出局部保持投影(LPP)算法以及应用于人脸识别中的拉普拉斯脸方法。LPP 算法根据样本之间的距离关系确定样本的相似度,在投影时能保持人脸图像的局部结构<sup>[13]</sup>。LPP 算法属于一种无监督的降维方法,其忽略数据的类别信息,对不同类别之间的数据判别效果较差。针对该缺陷,近年来学者在 LPP 算法基础上结合数据类别信息,利用局部 Fisher 判别分析算法(LFDA)<sup>[14]</sup>和边际 Fisher 分析算法(MFA)<sup>[15]</sup>等监督<sup>[16-17]</sup>或半监督算法<sup>[18]</sup>进行人脸识别。LFDA 算法通过最小化类内散布矩阵和最大化类间散布矩阵使数据在投影空间中具有最佳的可分性,但最优投影方向受近邻点个数的选择影响较大。MFA 算法通过分析近邻数据点之间的几何关系挖掘数据分布的统计特性,对类内数据的紧密性和类间数据的分离性分别定义描述准则,但该算法对邻域选取较敏感。

此外,传统的 LPP 算法虽然在子空间中进行投影,但选择近邻和确定相似度时仍然利用数据在原始空间的距离特征。通常原始数据会包含噪声等冗余特征,并不能很好地反映数据之间的真实相似性。为了解决 LPP 算法中近邻选取不准确的问题,提出了基于投影子空间的特征提取算法<sup>[19-21]</sup>。其中, Pang 等<sup>[19]</sup>提出的同时学习近邻和投影矩阵的监督降维(SLNP)算法,将相似性和近邻作为变量,并在低维子空间中建模,在投影子空间中对邻接矩阵和投影矩阵进行优化,提高了投影和分类的准确性。

针对上述问题,本文提出一种基于自适应近邻的局部保持投影算法,并将其应用于人脸识别中。该算法自适应选取近邻,随着投影矩阵的变化实时更新近邻点,并在投影子空间中对投影矩阵和邻接矩阵进行约束。同时利用数据类别信息,对同类样本和异类样本进行不同的约束,构建目标函数。通过最小化目标函数得到最优的投影矩阵,对人脸样本进行投影降维,从而完成人脸的分类识别。该算法克服了 LPP 算法的缺陷,在近邻的选择上依赖样本在投影子空间中的特征,能够体现出不同类样本间的差异性。实验结果表明,本文算法具有较好的人脸识别效果。

## 2 相关算法与优化

### 2.1 LPP 算法

LPP 算法的目标是构建空间中样本之间的相

似度关系,并在投影中保持样本点的局部信息,使得近邻点在低维子空间仍为近邻。设  $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n)$  为原始空间  $\mathbf{R}^D$  中的样本数据集,样本数为  $n$ ,数据维数为  $D$ ,定义样本之间相似度关系的邻接矩阵  $\mathbf{S}$ ,对于  $\mathbf{X}$  中的第  $i$  个和第  $j$  个样本  $\mathbf{x}_i$ 、 $\mathbf{x}_j$ ,相似度为

$$s_{ij} = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{t}\right), \quad (1)$$

由(1)式可知,LPP 算法中的相似度为一个由特征向量  $\mathbf{x}_i$  和  $\mathbf{x}_j$  之间的距离所确定的函数,参数  $t$  为根据经验设定的常量。设投影向量为  $\mathbf{w}$ ,则 LPP 的目标函数可以定义为

$$\begin{aligned} \omega^* &= \arg \min_{\mathbf{w}} \sum_{i \neq j} s_{ij} \|\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \mathbf{x}_j\|^2 = \\ &= \arg \min_{\mathbf{w}} \mathbf{w}^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{w} = \\ &= \arg \min_{\mathbf{w}} \mathbf{w}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w}, \end{aligned} \quad (2)$$

式中  $\mathbf{D}$  为对角矩阵,对角线上的元素为邻接矩阵  $\mathbf{S}$  所对应的行和, $\mathbf{L} = \mathbf{D} - \mathbf{S}$  称为拉普拉斯矩阵。根据限制条件  $\mathbf{w}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{w} = 1$ ,可以将(2)式中求解最优投影向量问题转化为求解最小特征值对应的特征向量,即

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{w} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{w}, \quad (3)$$

投影矩阵  $\mathbf{W}$  即为(3)式中最小的  $d$  个特征值对应的特征向量,记为  $\mathbf{W} = (\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d)$ 。

LPP 算法定义的相似度是基于原始空间特征信息的定值。在很多情况下,原始空间的特征信息并不能很好地反映数据在投影子空间中的特征,这会造成近邻选取与相似度计算不准确。此外,LPP 算法虽然考虑数据的局部信息,但是在计算相似度时忽略类别信息的影响。当两类样本特征接近时,局部保持的特性会使两类样本在投影后混淆到一起,进而造成算法的稳健性不佳。

为了解决 LPP 算法的上述缺陷,本文提出两种解决方案。首先,改进文献[19]中 SLNP 方法在投影子空间中动态选取近邻的方法,将投影矩阵和邻接矩阵的求解作为一个最优化问题,通过迭代方式求出最优解,与 SLNP 方法相比,改进方法重新定义了进行约束的正则化参数项,将正则化参数表示为与投影距离相关的变量,同时优化目标函数求解过程,减少迭代时的参数数量,使算法更简洁;其次,利用数据的类别信息处理样本间的关系,对同类样本选取合适的近邻点,最小化类内投影距离使得投影后样本尽可能接近;对异类样本分别提取每一类

样本的特征,并定义类间相似度,最大化类间投影距离,使得投影后样本尽可能远离。改进后的算法与传统 LPP 算法相比能够选取更佳的投影方向,同时能够提高分类准确性。

## 2.2 邻接矩阵的构造

设  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$  为原始空间  $\mathbf{R}^D$  中的样本数据集,类别数为  $c$ ,投影后维数为  $d$ 。算法目的是通过投影矩阵  $\mathbf{W} \in \mathbf{R}^{D \times d}$  得到数据集  $\mathbf{X}$  的低维映射数据集  $\mathbf{Y} \in \mathbf{R}^{n \times d}$ ,其中  $d < D$ ,且  $\mathbf{Y} = \mathbf{W}^T \mathbf{X}$ 。

定义类内邻接矩阵  $\mathbf{S}_w^{[19]}$ :首先提取每个样本的标签特征  $c_l \in (1, 2, \dots, c)$ ,并独立处理每一类样本包含的所有数据,第  $l$  类样本个数为  $n_l$ ,设定每类样本的近邻个数为  $k (k < n_l)$ 。通常,对于同一类的任意两个近邻样本  $\mathbf{x}_i$  和  $\mathbf{x}_j$ ,样本之间的距离  $\|\mathbf{x}_i - \mathbf{x}_j\|^2$  越小,样本的相似性越大。在投影子空间中同样遵循这一原则,为使所有样本两两间的投影距离之和最小,将求解类内邻接矩阵问题转化为求解最小值问题,即求取

$$\min_{s_{w_{ij}}^{i,j=1}^{n_l}} \sum_{i,j=1}^{n_l} s_{w_{ij}} \|\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j\|^2. \quad (4)$$

然而,(4)式中类内相似度  $s_{w_{ij}}$  仅受样本在投影子空间的距离影响,当(4)式取得最小值时,只有该距离最近的两点之间的相似度为 1,其余各点之间相似度均为 0,即只有距离最近的点可以被选作近邻。因此需要添加一项不含距离信息的约束项  $s_{w_{ij}}^2$ ,以选取合适的近邻数,此时,最小值问题可以转化为求取

$$\min_{s_{w_{ij}}^{i,j=1}^{n_l}} \sum_{i,j=1}^{n_l} (s_{w_{ij}} \|\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j\|^2 + \gamma s_{w_{ij}}^2), \quad (5)$$

式中  $\gamma s_{w_{ij}}^2$  为正则项, $\gamma$  为正则化参数。正则化参数项可以减小样本训练误差,并提高公式的泛化能力,设定合适的  $\gamma$  可以得到满足条件的近邻。在(5)式中,类内相似度  $s_{w_{ij}}$  不再是一个定值,而是一个在投影子空间中与投影矩阵  $\mathbf{W}$  相关的变量,可以通过迭代方法优化,最终得到公式的整体最小值。类内邻接矩阵中每一点的值定义为

$$\mathbf{S}_{w_{ij}}^* = \begin{cases} \arg \min_{s_{w_{ij}}} \sum_{i,j=1}^{n_l} (s_{w_{ij}} \|\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j\|^2 + \gamma s_{w_{ij}}^2), \\ \mathbf{x}_i \text{ and } \mathbf{x}_j \text{ neighbors} \\ 0, \\ \mathbf{x}_i \text{ and } \mathbf{x}_j \text{ not neighbors} \end{cases}. \quad (6)$$

同样,近邻点的选择也不再固定,而是在优化投

影矩阵时,随着样本在投影子空间的距离变化重新确定。这样可以始终保证近邻选择的是样本在投影子空间中的距离最近点,不会因初始近邻选择的好坏影响降维效果。

类内邻接矩阵  $\mathbf{S}_w$  用来表示同类数据点的相似程度,但(6)式只反映同类样本点两两之间的关系,在投影时没有结合样本的类别信息,无法保证投影后异类样本之间仍然具有较好的区分性。因此对于异类数据点,同样定义类间邻接矩阵  $\mathbf{S}_B$  表示异类样本的相似程度,使得投影子空间中同类数据点趋近的同时,异类数据点之间尽可能远离。

定义类间邻接矩阵  $\mathbf{S}_B$ :通常对于一个样本点集,异类样本的数量要远远超过同类样本。如果为每两个异类样本之间都定义一个相似度,不仅会使类间邻接矩阵结构复杂,而且无法体现异类之间的差异性。因此本文选取每一类所有样本的均值作为该类样本的中心,计算各中心点之间的相似度并构建类间邻接矩阵。先提取每个样本的标签特征  $c_l \in (1, 2, \dots, c)$ ,对于第  $l$  类的所有  $n_l$  个样本,定义中心点为  $\bar{\mathbf{x}}_l = \frac{1}{n_l} \sum_{i=1}^{n_l} \mathbf{x}_i$ 。参考 LPP 算法中相似度的定义,在投影子空间中类间邻接矩阵  $\mathbf{S}_B$  中,点  $s_{B_{lm}}$  可以定义为

$$s_{B_{lm}} = \exp\left(-\frac{\|\mathbf{W}^T \bar{\mathbf{x}}_l - \mathbf{W}^T \bar{\mathbf{x}}_m\|^2}{t}\right), \quad (7)$$

式中  $\bar{\mathbf{x}}_l$  和  $\bar{\mathbf{x}}_m$  为不同类别的样本中心点。对异类数据点的优化等价于求取

$$\max_{s_{B_{lm}}^{l,m=1}^c} \sum_{l,m=1}^c s_{B_{lm}} \|\mathbf{W}^T \bar{\mathbf{x}}_l - \mathbf{W}^T \bar{\mathbf{x}}_m\|^2. \quad (8)$$

结合(5)式和(8)式构造整体的目标函数  $J$ ,其由类内和类间优化函数  $J_w^{[19]}$ 、 $J_B$  两部分组成,通过优化取得目标函数的最小值,从而得到投影矩阵,投影后的低维数据具有很好的区分性。此时有

$$J = J_w - \beta J_B, \quad (9)$$

式中  $\beta$  为调节类内和类间优化函数关系的常量, $J_w$  和  $J_B$  可分别定义为

$$J_w = \sum_{l=1}^c \sum_{i,j=1}^{n_l} [s_{w_{ij}} \|\mathbf{W}^T (\mathbf{x}_i - \mathbf{x}_j)\|^2 + \gamma s_{w_{ij}}^2], \quad (10)$$

$$J_B = \sum_{l,m=1}^c s_{B_{lm}} \|\mathbf{W}^T (\bar{\mathbf{x}}_l - \bar{\mathbf{x}}_m)\|^2. \quad (11)$$

本文算法的目的是在投影子空间中实现投影矩阵  $\mathbf{W}$  和邻接矩阵  $\mathbf{S}_w$ 、 $\mathbf{S}_B$  的同时优化,最终使目标函数  $J$  能够取得最小值,进而得到最理想的  $\mathbf{W}$ 。

### 3 算法求解

(9)式中,目标函数  $J$  主要取决于投影矩阵  $\mathbf{W}$  和邻接矩阵  $\mathbf{S}$ ,而  $\mathbf{W}$  和  $\mathbf{S}$  相互约束、相互影响,同时求解两个变量会增大计算难度。因此采用迭代方法,依次固定其中一个参数并优化另一个参数,直至目标函数值趋于稳定,此时得到的  $\mathbf{W}$  即为最优投影矩阵。

#### 3.1 邻接矩阵的求解

首先固定投影矩阵  $\mathbf{W}$ ,求解邻接矩阵  $\mathbf{S}$ ,则目标函数  $J$  的最小值可以表示为

$$\min_{\mathbf{S}} \left[ \sum_{l=1}^c \sum_{i,j=1}^{n_l} (s_{w_{ij}} \|\mathbf{W}^T(\mathbf{x}_i - \mathbf{x}_j)\|^2 + \gamma s_{w_{ij}}^2) - \beta \sum_{l,m=1}^c s_{B_{lm}} \|\mathbf{W}^T(\bar{\mathbf{x}}_l - \bar{\mathbf{x}}_m)\|^2 \right], \quad (12)$$

式中当  $\mathbf{W}$  固定时,样本点在投影子空间中的距离可视为定值,分别定义  $d_{ij} = \|\mathbf{W}^T(\mathbf{x}_i - \mathbf{x}_j)\|^2$  和  $d_{lm} = \|\mathbf{W}^T(\bar{\mathbf{x}}_l - \bar{\mathbf{x}}_m)\|^2$  表示类内样本和类间样本的投影距离,此时,可将(12)式化简为

$$\min_{\mathbf{S}} \left[ \sum_{l=1}^c \sum_{i,j=1}^{n_l} (s_{w_{ij}} d_{ij} + \gamma s_{w_{ij}}^2) - \beta \sum_{l,m=1}^c s_{B_{lm}} d_{lm} \right], \quad (13)$$

由(7)式可知,当  $d_{lm}$  为定值时,  $s_{B_{lm}}$  只与参数  $t$  有关,因此问题转化为求解类内邻接矩阵  $\mathbf{S}_w$  的最小值。

对(13)式中的  $s_{w_{ij}}$  求导,并添加约束条件  $\sum_j s_{w_{ij}} = 1, 0 \leq s_{w_{ij}} \leq 1$ ,即可将求解  $s_{w_{ij}}$  转化为求最优解的问题,即

$$\min_{\sum_j s_{w_{ij}}=1} \left\| s_{w_{ij}} + \frac{1}{2\gamma} d_{ij} \right\|^2, \quad (14)$$

因此,只需确定合适的正则化参数  $\gamma$  即可得到  $s_{w_{ij}}$  的最优解。使用拉格朗日乘子法求解参数  $\gamma$ ,在约束条件  $\sum_j s_{w_{ij}} = 1$  和  $0 \leq s_{w_{ij}} \leq 1$  下,拉格朗日函数可以表示为

$$L(s_{w_{ij}}, \eta, \lambda) = \frac{1}{2} \left\| s_{w_{ij}} + \frac{d_{ij}}{2\gamma} \right\|^2 - \eta (s_{w_{ij}}^T \mathbf{1} - 1) - \lambda^T s_{w_{ij}}, \quad (15)$$

式中  $\eta$  和  $\lambda \geq 0$  为拉格朗日乘数,根据 KTT 条件<sup>[22]</sup>,最理想的  $s_{w_{ij}}$  满足条件  $s_{w_{ij}} = -d_{ij}/2\gamma_{ij} + \eta$ ,且此时  $s_{w_{ij}}$  为正值,即

$$\begin{cases} -\frac{d_{ij}}{2\gamma_{ij}} + \eta > 0 \\ -\frac{d_{i,j+1}}{2\gamma_{ij}} + \eta \leq 0 \end{cases}, \quad (16)$$

当近邻个数为  $k$  时,投影距离  $d_{ij}$  由小到大(即  $d_{ij} \leq d_{i,j+1}$ ),依次设  $\mathbf{x}_i$  的  $k$  个近邻点分别为  $\mathbf{x}_j (j=1, 2, \dots, k)$ ,由  $s_{w_{ij}}$  的约束条件可得

$$\sum_{j=1}^k \left( -\frac{d_{ij}}{2\gamma_{ij}} + \eta \right) = 1 \Rightarrow \eta = \frac{1}{k} + \frac{1}{2k\gamma_{ij}} \sum_{j=1}^k d_{ij}. \quad (17)$$

由(16)式和(17)式可得

$$\frac{k}{2} d_{ik} - \frac{1}{2} \sum_{j=1}^k d_{ij} < \gamma_{ij} \leq \frac{k}{2} d_{i,k+1} - \frac{1}{2} \sum_{j=1}^k d_{ij}, \quad (18)$$

(18)式中能够取得的  $\gamma_{ij}$  均符合条件,因此可以取

$\gamma_{ij} = \frac{k}{2} d_{i,k+1} - \frac{1}{2} \sum_{j=1}^k d_{ij}$  作为设定的参数  $\gamma$ ,代入(14)式即可求得类内邻接矩阵  $\mathbf{S}_w$ 。

#### 3.2 投影矩阵的求解

固定邻接矩阵  $\mathbf{S}$ ,求解投影矩阵  $\mathbf{W}$ ,则目标函数  $J$  的最小值可以表示为

$$\min_{\mathbf{W}} \left\{ \sum_{l=1}^c \sum_{i,j=1}^{n_l} [s_{w_{ij}} \|\mathbf{W}^T(\mathbf{x}_i - \mathbf{x}_j)\|^2] - \beta \sum_{l,m=1}^c s_{B_{lm}} \|\mathbf{W}^T(\bar{\mathbf{x}}_l - \bar{\mathbf{x}}_m)\|^2 \right\}. \quad (19)$$

根据(2)式中拉普拉斯矩阵的定义,同样将求解目标函数的最小值问题转化为求解投影矩阵最小值问题,即

$$\mathbf{W}^* = \arg \min_{\mathbf{W}} [\mathbf{W}^T \mathbf{X} (\mathbf{D}_w - \mathbf{S}_w) \mathbf{X}^T \mathbf{W} -$$

$$\beta \mathbf{W}^T \bar{\mathbf{X}} (\mathbf{D}_B - \mathbf{S}_B) \bar{\mathbf{X}}^T \mathbf{W}] =$$

$$\arg \min_{\mathbf{W}} [\mathbf{W}^T (\mathbf{X} \mathbf{L}_w \mathbf{X}^T - \beta \bar{\mathbf{X}} \mathbf{L}_B \bar{\mathbf{X}}^T) \mathbf{W}], \quad (20)$$

式中  $\mathbf{L}_w$  和  $\mathbf{L}_B$  分别为类内拉普拉斯矩阵和类间拉普拉斯矩阵。为了求解(20)式,添加白化约束条件  $\mathbf{W}^T \mathbf{S}_l \mathbf{W} = \mathbf{I}$ ,使得所有的样本具有相同的方差特征,

$\mathbf{S}_l$  代表散射矩阵  $\mathbf{S}_l = \sum_{l=1}^c \sum_{i=1}^{n_l} (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$ ,  $\bar{\mathbf{x}}$  为所有样本的中心点。因此,(20)式的最优化问题等价于求解

$$\mathbf{W}^* = \arg \min_{\mathbf{W}^T \mathbf{S}_l \mathbf{W} = \mathbf{I}} \text{tr} [\mathbf{W}^T (\mathbf{X} \mathbf{L}_w \mathbf{X}^T - \beta \bar{\mathbf{X}} \mathbf{L}_B \bar{\mathbf{X}}^T) \mathbf{W}], \quad (21)$$

式中  $\text{tr}$  代表矩阵的迹,  $\mathbf{W}$  可以表示为  $\mathbf{S}_l^{-1} (\mathbf{X} \mathbf{L}_w \mathbf{X}^T - \beta \bar{\mathbf{X}} \mathbf{L}_B \bar{\mathbf{X}}^T)$ ,取该矩阵最小的  $d$  个特征值所对应的特

征向量,即可得到当前的投影矩阵  $W$ 。

重复迭代上述求解  $W$  和  $S$  的步骤,每一次迭代时重新选择近邻点和计算邻接矩阵,目标函数值也会逐渐减小,直至趋于稳定。经过多次迭代得到的  $W$  即为所求投影矩阵。在人脸识别中,使用求出的  $W$  对测试样本进行降维,并计算测试样本的类别标签,即可实现人脸图片的分类识别。

### 3.3 算法步骤

本文提出的基于自适应近邻的局部保持投影算法的具体步骤如下。

输入:数据集  $X=(x_1, x_2, \dots, x_n)$ , 样本数  $n$ , 原始维数  $D$ , 投影后维数  $d$ , 类别数  $c$  以及标签信息, 近邻个数  $k$ , 参数  $t, \beta$ 。

输出:投影矩阵  $W \in R^{D \times d}$ , 邻接矩阵  $S$ 。

1) 初始化邻接矩阵  $S$ ;

2) 固定  $S$ , 求解  $W$ , 对每一类样本, 分别根据公式  $L=D-S$  计算  $L_W$  和  $L_B$ , 代入(21)式, 求出最小的  $d$  个特征值所对应的特征向量构成的投影矩阵  $W$ ;

3) 固定  $W$ , 求解  $S$ , 根据(18)式和(14)式求得  $S_W$ , 根据(13)式求得  $S_B$ ;

4) 重复 2)~3), 不断更新  $S$  和  $W$ , 直至参数趋于稳定, 输出  $W$ 。

本文算法的流程如图 1 所示。在进行人脸识别时, 将训练样本作为数据集  $X$ , 根据上文步骤求出投影矩阵  $W$ , 并对测试样本进行降维。对于每一个投影子空间上的测试样本点, 选择该点与训练样本的低维映射数据集距离最小点标签作为类别标签, 直

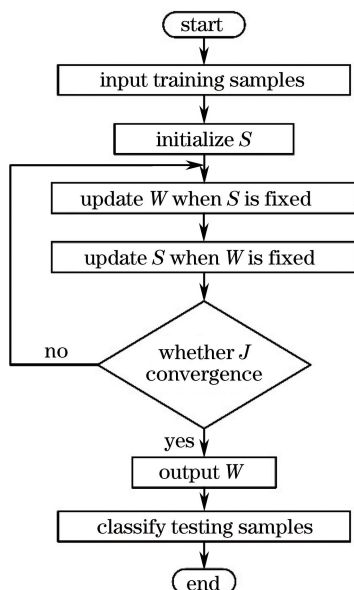


图 1 算法流程图

Fig. 1 Flow chart of algorithm

至完成所有点的分类。

## 4 实验与结果分析

### 4.1 数据库介绍

为了验证本文算法在人脸识别中的有效性, 分别在扩展 Yale 人脸数据库(Yale B)、CMU-PIE 人脸数据库(PIE)、MSRA 人脸数据库(MSRA)和 CAS-PEAL 人脸数据库(CAS-PEAL)中进行实验。实验的硬件环境为 3.7 GHz Intel Core i7 CPU, 16 GB RAM 计算机, 软件环境为 Matlab R2014a。Yale B 数据库包含 38 个人的 16128 张人脸图像, 包括 9 种姿态和 64 种光照条件下的图像, 实验中选取其子集 3456 张人脸图像, 每张图像大小为 192 pixel  $\times$  168 pixel; PIE 数据库由美国卡耐基梅隆大学创建, 包含 68 位志愿者的 41368 张多姿态、光照和表情的面部图像, 实验中选取其子集 3329 张人脸图像, 每张图像大小为 64 pixel  $\times$  64 pixel; MSRA 数据库包含 12 个人的 1799 张人脸图像, 每张图像大小为 64 pixel  $\times$  64 pixel; CAS-PEAL 数据库包含 1042 个人的 30863 张人脸图像, 包含不同的姿态、表情、饰物和光照变化下的图像, 实验中选取其子集 10000 张人脸图像, 每张图片大小为 64 pixel  $\times$  64 pixel。图 2 所示为 4 个人脸数据库的图像示例。

实验前先使用 PCA 算法对原始数据进行降维预处理, 去除样本中的奇异点, 在保持运算精度的同时提高训练速度<sup>[23]</sup>。通常, 降维后的维数  $D_{PCA}$  的选择受样本的原始维度和类别数目影响, 样本的原始维度越高, 样本类别数越大, 样本中包含的数据特征越丰富,  $D_{PCA}$  取值也越大。  $D_{PCA}$  分别选取 180 (Yale B)、160 (PIE)、45 (MSRA) 和 750 (CAS-PEAL) 作为 4 种数据库预处理后的维数, 各数据库的具体描述如表 1 所示。

### 4.2 收敛性验证

为了验证算法的收敛性, 在 Yale B 数据库中进行算法收敛性验证实验。随机选取每类数据中 10 个样本作为训练样本, 其余作为测试样本, 近邻数  $k=5$ , 参数  $t=25$ , 参数  $\beta=1$ 。每次迭代完成后, 计算当前目标函数  $J$ , 图 3 所示为迭代次数与目标函数  $J$  之间的关系。随着迭代次数的增加,  $J$  不断减小直至趋于稳定, 当迭代次数为 10 时, 目标函数实现收敛。结果表明, 本文算法可以在迭代过程中同时对参数  $W$  和  $S$  进行优化, 直到收敛后得到最优的结果。



图2 数据库图像示例。(a) Yale B;(b) PIE;(c) MSRA;(d) CAS-PEAL

Fig. 2 Sample images of (a) Yale B, (b) PIE, (c) MSRA, and (d) CAS-PEAL database

表1 人脸数据库的具体描述

Table 1 Detail descriptions of face databases

Database	Sample	Class	Samples per class	Sample size / (pixel×pixel)	Original dimension	PCA dimension
Yale B	3456	38	59-64	192×168	32256	180
PIE	3329	68	46-49	64×64	4096	160
MSRA	1799	12	113-186	64×64	4096	45
CAS-PEAL	10000	400	25	64×64	4096	750




图3 迭代次数和目标函数值  $J$  的关系

Fig. 3 Relationship between iteration number and objective function  $J$

### 4.3 最优维度的选取

对于不同的数据库,样本点的本征维数与数据库本身的特性有关,投影后维数  $d$  的选择对分类效果的影响很大。为了选取最佳的投影维数  $d$ ,分别在 Yale B、PIE、MSRA 数据库中进行实验。随机选取每类数据中 10 个样本作为训练样本,其余作为测试样本,近邻数  $k=5$ ,参数  $t=25$ ,参数  $\beta=1$ 。

在 Yale B 数据库中,PCA 降维预处理后的维度为 180,在其他参数保持不变的情况下,依次选取所有

$d < D_{PCA}$  的值进行实验,得到的结果如图 4 所示,其中折线表示识别率与投影维数  $d$  之间的关系,开始时识别率随着  $d$  的增加而迅速增大,说明投影维数太小时无法体现样本的所有特征;当  $d=38$  时,识别率达到最大值,之后识别率趋于稳定并随着  $d$  的增加而缓慢减小,说明此时选取的投影特征较冗余。因此 Yale B 数据库的最佳投影维度  $d=38$ 。

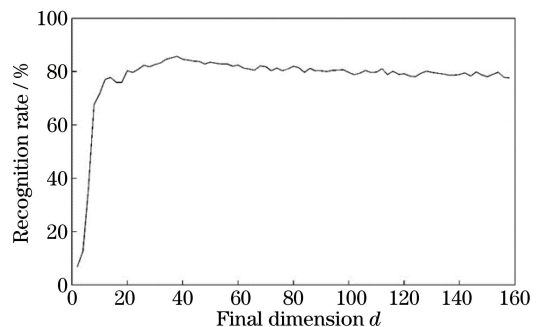


图4 Yale B 数据库中识别率与投影维数  $d$  的关系

Fig. 4 Relationship between recognition rate and final dimension  $d$  in Yale B database

PIE、MSRA 和 CAS-PEAL 数据库中的实验与 Yale B 数据库类似,保持其他参数不变,观察识别

率与投影维数  $d$  之间的关系, 所得结果分别如图 5~7 所示。由图可知, PIE、MSRA 和 CAS-PEAL 数据库的最佳投影维度分别为 66、14、380。

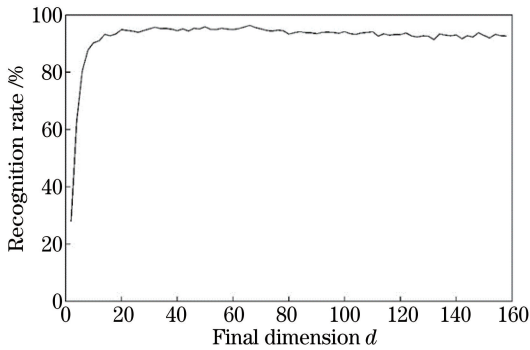


图 5 PIE 数据库中识别率与投影维数  $d$  的关系  
Fig. 5 Relationship between recognition rate and final dimension  $d$  in PIE database




图 6 MSRA 数据库中识别率与投影维数  $d$  的关系  
Fig. 6 Relationship between recognition rate and final dimension  $d$  in MSRA database

#### 4.4 分类效果比较

分别在 Yale B、PIE、MSRA 和 CAS-PEAL 数据库中进行人脸识别实验, 并与 LDA、MFA、LPP、




图 7 CAS-PEAL 数据库中识别率与投影维数  $d$  的关系  
Fig. 7 Relationship between recognition rate and final dimension  $d$  in CAS-PEAL database

LFDA 以及 SLNP 算法进行对比, 以验证本文算法的性能。分别随机选取每类数据中 5、10、20 个样本作为训练样本, 其余作为测试样本,  $k=5$  (训练样本个数为 5 时,  $k=3$ ),  $t=25$ ,  $\beta=1$ 。  $d$  分别取 38 (Yale B)、66 (PIE)、14 (MSRA) 和 380 (CAS-PEAL)。表 2 给出了各算法在 4 种数据库中的识别率。

分析表 2 数据可知, 传统的 LDA、MFA、LFDA 和 LPP 算法在人脸识别上效果不佳。其中, MFA 算法结果不稳定, 在不同数据库中识别率差异较大, 在 Yale B 数据库中最高识别率仅为 71.95%; LFDA 算法在训练样本个数较少时效果不佳, 在 MSRA 数据库中训练样本为 5 时识别率仅为 58.46%; 而 LDA 和 LPP 算法结果虽然较 MFA、LFDA 算法更稳定, 但由于没有利用类别标签信息, 在各个数据库上整体识别率不高; SLNP 算法的识别率明显高于 LDA、MFA、LFDA 和 LPP 等算法; 与 SLNP 算法相比, 本文算法在不同数据库中识别效果普遍提高了 1%~2%。

表 2 不同数据库中算法识别率对比

Table 2 Comparison of algorithm recognition rate in different databases

Method	Yale B database			PIE database			MSRA database			CAS-PEAL database		
	5	10	20	5	10	20	5	10	20	5	10	20
LDA	64.55	80.65	89.78	62.47	77.52	92.46	87.65	95.63	98.78	48.75	63.81	77.63
MFA	51.23	66.67	71.95	78.62	89.39	93.69	85.32	93.04	98.28	45.69	65.13	79.81
LFDA	61.88	78.43	87.01	74.68	88.01	94.87	58.46	72.76	97.67	39.23	61.92	80.60
LPP	63.86	79.14	88.12	83.94	92.95	95.32	86.73	95.38	98.40	43.95	67.39	78.66
SLNP	70.14	84.02	93.71	86.31	94.16	96.37	88.91	96.79	99.02	62.91	73.92	83.54
Proposed	<b>72.53</b>	<b>85.71</b>	<b>94.46</b>	<b>88.26</b>	<b>96.34</b>	<b>98.84</b>	<b>90.63</b>	<b>98.22</b>	<b>99.34</b>	<b>65.83</b>	<b>75.64</b>	<b>86.76</b>

不同算法的识别效果随着训练样本数目的增加而提高。当训练样本数不同时, 本文算法的识别率与其他算法相比均有所提高。以 Yale B 数据库为例, 训练样本个数为 5、10、20 时, 识别率可以分别达到 72.53%、85.71% 和 94.46%, 较其他算法的识别

率分别至少提高了 2.39%、1.69% 和 0.75%。因此对于不同的人脸数据库, 无论训练样本数目多少, 本文算法都可以取得很好的分类效果。

实验结果表明, 本文算法应用于人脸识别上取得了很好的效果, 在 Yale B、PIE、MSRA 和 CAS-

PEAL 数据库中的最高识别率分别达到了 94.46%、98.84%、99.34% 和 86.76%，明显高于传统的特征提取算法。

## 5 结 论

将基于自适应近邻的局部保持投影算法应用于人脸识别,利用类内信息和类间信息构建目标函数,在投影子空间中动态选择近邻,并将投影矩阵与邻接矩阵的优化相结合,在约束条件下求得最小的目标函数,实现人脸数据分类。

作为一种面向分类的监督算法,本文算法有效解决了 LPP 算法忽略投影子空间特征,以及忽略标签信息的问题。在 Yale B、PIE、MSRA 和 CAS-PEAL 数据库上的实验结果表明,与传统特征提取算法相比,本文算法的识别率明显提高,证明该算法能有效进行人脸识别。

## 参 考 文 献

- [1] Xia J, Pei D, Wang Q Z, *et al.* Face recognition based on local adaptive ternary derivative pattern coupled with Gabor feature [J]. *Laser & Optoelectronics Progress*, 2016, 53(11): 111004.  
夏军, 裴东, 王全州, 等. 融合 Gabor 特征的局部自适应三值微分模式的人脸识别[J]. *激光与光电子学进展*, 2016, 53(11): 111004.
- [2] Pang Y W, Liu Z K, Yu N H. A new nonlinear feature extraction method for face recognition [J]. *Neurocomputing*, 2006, 69(7): 949-953.
- [3] Chihaoui M, Elkefi A, Bellil W, *et al.* A survey of 2D face recognition techniques[J]. *Computers*, 2016, 5(4): 21.
- [4] Cui P, Yan T T. A SVM-based feature extraction for face recognition[J]. *Pattern Recognition*, 2016, 43(8): 2871-2881.
- [5] Xu Y, Fang X Z, Wu J, *et al.* Discriminative transfer subspace learning via low-rank and sparse representation [J]. *IEEE Transactions on Image Processing*, 2016, 25(2): 850-863.
- [6] Liu G C, Lin Z C, Yan S C, *et al.* Robust recovery of subspace structures by low-rank representation [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2013, 35(1): 171-184.
- [7] Gao W J, Bai W R, Gong W J, *et al.* Orthogonal local sensitive discriminant analysis algorithm based on adaptive neighborhood choosing [J]. *Computer Engineering and Design*, 2012, 33(5): 1968-1972.

高玮军, 白万荣, 公维军, 等. 基于自适应邻域选择的正交局部敏感判别分析[J]. *计算机工程与设计*, 2012, 33(5): 1968-1972.

- [8] Tipping M E, Bishop C M. Probabilistic principal component analysis [J]. *Journal of the Royal Statistical Society*, 1999, 61(3): 611-622.
- [9] Xu Y, Wei Z Y. An improved traffic sign image recognition algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(2): 021001.  
徐岩, 韦镇余. 一种改进的交通标志图像识别算法[J]. *激光与光电子学进展*, 2017, 54(2): 021001.
- [10] Pang Y W, Wang S, Yuan Y. Learning regularized LDA by clustering[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 25(12): 2191-2201.
- [11] He X, Niyogi P. Locality preserving projections (LPP) [C]//*Proceedings of the 16th International Conference on Neural Information Processing Systems*, 2003, 16(1): 186-197.
- [12] He X F, Yan S C, Hu Y X, *et al.* Face recognition using Laplacianfaces [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2005, 27(3): 328-40.
- [13] Zhang X, Yi H J, Hou Y Q, *et al.* Fast reconstruction in fluorescence molecular tomography based on locality preserving projections [J]. *Acta Optica Sinica*, 2016, 36(7): 0717001.  
张旭, 易黄建, 侯榆青, 等. 基于局部保留投影的荧光分子断层成像快速重建[J]. *光学学报*, 2016, 36(7): 0717001.
- [14] Jia J R, Ruan Q Q, Jin Y. Geometric preserving local fisher discriminant analysis for person re-identification[J]. *Neurocomputing*, 2016, 205(C): 92-105.
- [15] He J R, Ding L X, Jiang L, *et al.* A flexible and efficient algorithm for regularized Marginal Fisher analysis [C]//*International Joint Conference on Neural Networks*, 2014: 4198-4205.
- [16] Dornaika F, Assoum A. Enhanced and parameterless locality preserving projections for face recognition [J]. *Neurocomputing*, 2013, 99(1): 448-457.
- [17] Li Q Q, Yang H X, Feng J P, *et al.* Face recognition algorithm based on 2DPCA+2DLDA and improved LPP [J]. *Computer Engineering and Applications*, 2015, 51(21): 199-204.  
李球球, 杨恢先, 奉俊鹏, 等. 2DPCA+2DLDA 和改进的 LPP 相结合的人脸识别算法[J]. *计算机工程与应用*, 2015, 51(21): 199-204.



- [18] Ji Z, Pang Y W, He Y Q, *et al.* Semi-supervised LPP algorithms for learning-to-rank-based visual search reranking [J]. *Information Sciences*, 2015, 302(C): 83-93.
- [19] Pang Y W, Zhou B, Nie F P. Simultaneously learning neighborhood and projection matrix for supervised dimensionality reduction[EB/OL]. [2017-12-21]. <https://arxiv.org/abs/1709.02896>.
- [20] Xu Y, Fang X Z, Wu J, *et al.* Discriminative transfer subspace learning via low-rank and sparse representation [J]. *IEEE Transactions on Image Processing*, 2015, 25(2): 850-863.
- [21] Yang F F, Wu X S, Gu B Z. A face recognition algorithm based on low-rank subspace projection and Gabor feature via sparse representation[J]. *Computer Engineering & Science*, 2017, 39(1): 131-137.
- 杨方方, 吴锡生, 顾标准. 基于低秩子空间投影和 Gabor 特征的稀疏表示人脸识别算法[J]. *计算机工程与科学*, 2017, 39(1): 131-137.
- [22] Dreves A, Facchinei F, Kanzow C, *et al.* On the solution of the KKT conditions of generalized Nash equilibrium problems [J]. *Siam Journal on Optimization*, 2015, 21(3): 1082-1108.
- [23] Yu Z J, Wang S B. Improved PCA-SIFT algorithm for matching stereo system [J]. *Laser & Optoelectronics Progress*, 2016, 53(3): 031501.
- 于之靖, 王韶彬. 改进 PCA-SIFT 算法的立体匹配系统[J]. *激光与光电子学进展*, 2016, 53(3): 031501.