

# 基于流形学习和稀疏约束的快速特征提取算法

任迎春<sup>1,2</sup> 王志成<sup>1</sup> 陈宇飞<sup>1</sup> 赵卫东<sup>1</sup> 彭磊<sup>3</sup>

(同济大学 CAD 研究中心 上海 201804)<sup>1</sup> (嘉兴学院数理与信息工程学院 嘉兴 314001)<sup>2</sup>

(泰山医学院信息工程学院 泰安 271016)<sup>3</sup>

**摘要** 针对稀疏保持投影算法在特征提取过程中无监督和 L1 范数优化的计算量较大的问题,提出一种基于流形学习和稀疏约束的快速特征提取算法。首先通过逐类 PCA 构造级联字典,并基于该字典通过最小二乘法快速学习稀疏保持结构;其次构造用于描述不同子流形距离的局部类间散度函数;然后整合所学习到的稀疏表示信息和局部类间散度信息以达到既考虑判别效率又保持稀疏表示结构的目的;所提算法最终转化为一个求解广义特征值问题。在公共人脸数据库(Yale, ORL 和 Extended Yale B)中的测试结果验证了该方法的可行性和有效性。

**关键词** 特征提取,稀疏表示,主元分析,流形学习,人脸识别

**中图法分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.8.056

## Fast Feature Extraction Algorithm Based on Manifold Learning and Sparsity Constraints

REN Ying-chun<sup>1,2</sup> WANG Zhi-cheng<sup>1</sup> CHEN Yu-fei<sup>1</sup> ZHAO Wei-dong<sup>1</sup> PENG Lei<sup>3</sup>

(CAD Research Center, Tongji University, Shanghai 201804, China)<sup>1</sup>

(College of Mathematics, Physics and Information Engineering, Jiaxing University, Jiaxing 314001, China)<sup>2</sup>

(College of Information Engineering, Taishan Medical University, Taian 271016, China)<sup>3</sup>

**Abstract** Aiming at the problems of being unsupervised and time-consuming of L1 norm optimization in the existing sparsity preserving projection, by integrating the sparse representation information with the manifold structure of the data, a novel algorithm for fast feature extraction, named sparsity preserving discriminative learning (SPDL), was proposed. SPDL first creates a concatenated dictionary by class-wise PCA decompositions and learns the sparse representation structure of each sample under the constructed dictionary using the least square method. Secondly, a local between-class separability function is defined to characterize the scatter of the samples in different sub-manifolds. Then SPDL integrates the learned sparse representation information with the local between-class relationship to construct a discriminant function. Finally, the proposed method is transformed into a problem of solving the generalized eigenvalue. Extensive experimental results on several public face databases demonstrate the effectiveness of the proposed approach.

**Keywords** Feature extraction, Sparse representation, Principal component analysis, Manifold learning, Face recognition

## 1 引言

在诸如目标识别<sup>[1]</sup>、文本分类<sup>[2]</sup>、信息检索<sup>[3]</sup>等很多科学研究领域,数据常常以非常高维的形式出现。这些高维的数据常常难以被人理解、描述和识别。在实践中,特征提取是处理高维数据问题的有效手段<sup>[4-6]</sup>,通过特征提取能够降低数据的维数,得到高维数据的有效低维表示,以便理解其内在结构及后续处理。迄今为止,人们提出了很多特征提取的方法。基于所利用的数据结构,可将这些方法分为 3 类:基于全局结构的方法、基于局部结构的方法和基于稀疏表示的方法。

主元分析(Principal Component Analysis, PCA)<sup>[7]</sup>和线性判别分析(Linear Discriminant Analysis, LDA)<sup>[8]</sup>是基于全局结构的特征提取算法,这些算法具有坚实的理论基础,易于执行和分析,应用广泛。但 PCA 和 LDA 均基于高维数据空间的嵌入子空间是线性的这一假设,难以发现隐藏在高维数据中的局部流形特征。

为充分挖掘隐藏在低维数据中的局部流形结构,人们提出了多种基于流形学习的特征提取算法,主要包括等距映射(Isomap)<sup>[9]</sup>、拉普拉斯映射(Laplacian Eigenmaps, LE)<sup>[10]</sup>、局部线性嵌入(Local Linear Embedding, LLE)<sup>[11]</sup>、局部保持投

到稿日期:2015-07-09 返修日期:2016-01-05 本文受国家自然科学基金(61103070, 11301226),浙江省自然科学基金(LQ13A010017),山东省自然科学基金(ZR2015FL005)资助。

任迎春(1982-),男,博士生,主要研究方向为模式识别、机器学习及计算机视觉, E-mail: renyingchun2008@163.com;王志成(1975-),男,副研究员,硕士生导师,主要研究方向为模式识别及计算机视觉, E-mail: zhichengwang@tongji.edu.cn(通信作者);陈宇飞(1982-),女,博士,主要研究方向为机器学习及计算机视觉;赵卫东(1965-),男,研究员,博士生导师,主要研究方向为模式识别、机器学习及计算机视觉;彭磊(1977-),男,博士生,主要研究方向为计算机视觉。

影(Locality Preserving Projection, LPP)<sup>[12]</sup>和邻域保持嵌入(Neighborhood Preserving Embedding, NPE)<sup>[13]</sup>等方法。LE及LLE都通过构造近邻图来保留样本的局部邻域结构,在一定程度上保持了原始数据的非线性流形,但它们均面临“out-of-sample”问题<sup>[14]</sup>。有学者证明LPP和NPE分别是LE和LLE的线性化版本,虽有效克服了很多流形学习中面临的“out-of-sample”和计算复杂度过高的问题,但这两种方法都是从局部的角度出发,并未考虑原始样本空间中两个相距较远的样本在投影后的关系。

稀疏表示作为一种新的信号处理工具,已被成功应用于图像分类<sup>[15-17]</sup>、目标识别<sup>[18-20]</sup>和视频监控<sup>[21,22]</sup>等领域。稀疏表示旨在保持数据降维前后的稀疏表示结构,代表性的算法有SRC(Sparse Representation Classifier)<sup>[23]</sup>、SNMF(Sparse Nonnegative Matrix Factorization)<sup>[24]</sup>、SPP(Sparsity Preserving Projections)<sup>[25]</sup>、SPDA(Sparsity Preserving Discriminant Analysis)<sup>[26]</sup>等。上述算法较传统的降维算法在分类和识别效果上有显著提高。但这些算法都需要求解 $n$ 个耗时的稀疏优化问题,故难以在大规模数据处理问题中得到应用和推广。例如,SPP算法以保持数据的稀疏重构关系为目的,是一种较好的特征提取算法,但在处理过程中计算每个样本的稀疏向量时都需要求解一个L1范数优化问题,计算复杂度太高。另外,SPP并没有利用类标信息,而针对分类和识别问题,标签信息非常重要。基于此,Zang和Lu等人分别提出了DL-SP(Discriminative Learning by Sparse Representation Projections)<sup>[27]</sup>及DSNPE(Discriminant Sparsity Neighborhood Preserving Embedding)<sup>[28]</sup>算法。上述算法在稀疏保持投影的基础上,均加入了判别信息,进一步提高了SPP的特征提取效率和分类能力。但它们在构造稀疏权重图时依旧需要求解 $n$ 个耗时的L1范数最小化问题,故求解效率并未得到显著提高。

受以上算法的激励和启发,本文提出一种基于稀疏约束和流形学习的快速特征提取算法Sparsity Preserving Discriminative Learning(SPDL)。SPDL继承了稀疏表示和流形学习的优势,可以看作是两种维数约简方法的结合器。一方面,SPDL通过逐类PCA分解构造级联字典并基于该字典利用最小二乘法快速学习数据的稀疏表示结构,有效克服了传统稀疏优化算法面临的耗时的L1范数最小化问题;另一方面,SPDL重新定义了用于描述不同子流形距离的局部类间散度函数,旨在保持数据的稀疏表示结构的同时,使不同类的数据降维后间隔越来越大,这显然有利于问题的分类。SPDL具有以下几方面的优点:

(1)SPDL是线性和处处有定义的,因此不存在“out-of-sample”问题,这使它更具实用性。

(2)SPDL是一种新的特征提取方法,它在保持数据稀疏表示结构的同时促使不同子流形之间的距离投影后越来越大,这更有利于问题的分类。

(3)SPDL在运行时间上远远优于SPP。SPDL通过最小二乘法快速学习稀疏系数向量,而SPP需要求解 $n$ 个L1范数的优化问题,两者相比,SPDL学习稀疏表示结构的计算成本大大降低。

(4)SPDL两次利用了类标信息。首先在构造级联字典

和计算稀疏系数向量时利用了标签信息,这有利于求解一个更具判别性的稀疏表示结构;其次在计算局部类间散度函数时也利用了类标信息。

## 2 稀疏保持投影

SPP<sup>[25]</sup>通过稀疏重构处理,在保留样本稀疏重构信息的同时也保留了其全局近邻结构。首先,通过求解如下的L1范数最小化问题得到每个样本 $x_i$ 的稀疏系数向量 $s_i$ :

$$\min_{s_i} \|s_i\|_1, \text{ s. t. } x_i = Xs_i, \mathbf{1} = \mathbf{1}^T * s_i \quad (1)$$

由此得到稀疏重构权重矩阵:

$$S = [s_1, s_2, \dots, s_n] \quad (2)$$

最后,通过求解如下的优化问题得到最优投影向量

$$\max_W \frac{W^T X S S^T X^T W}{W^T X X^T W} \quad (3)$$

其中, $S_p = S + S^T - S^T S$ ,该优化问题最终转化为求解一个广义特征值问题。

从上述算法步骤可以看出,SPP在构造稀疏权重矩阵时需求解 $n$ 个L1范数的最小化问题,这对于大规模问题而言由于计算代价太大而无法广泛应用;另外,SPP是一种无监督学习模式,而对于分类和识别问题,充分利用类标信息是十分重要的。

## 3 SPDL 算法

本节将详述稀疏保持判别学习(SPDL)的思想。针对SPP在构造稀疏权重矩阵时需要求解 $n$ 个L1范数的计算量较大的问题,本文借助逐类PCA构造级联字典,并基于该字典通过最小二乘法快速学习稀疏保持结构;针对SPP在维数约简过程中的无监督问题,本文充分利用类标信息,定义用于描述不同子流形距离的局部类间散度函数,然后整合所学习到的稀疏表示信息和局部类间散度信息以达到既考虑判别效率又保持稀疏表示结构的目的。

### 3.1 构造级联字典

假设数据样本为 $X = \{x_1, x_2, \dots, x_n\}, x_i \in R^m$ ,令 $X = [X_1, X_2, \dots, X_K]$ ,其中 $X_i$ 表示第 $i$ 类样本, $X_i = [x_{i1}, x_{i2}, \dots, x_{in_i}] \in R^{m \times n_i}, i = 1, 2, \dots, K$ 。假设同类样本位于一个线性子空间中,则样本可由该类的若干原子线性表示。对每一类 $X_i$ 做主分量分析,其目标函数为

$$\max_{\|d\|=1} d^T \Sigma_i d \quad (4)$$

其中, $\Sigma_i$ 是 $X_i$ 的协方差矩阵。为PCA分解及相关计算方便起见,首先对每类数据做坐标平移使其中心位于原点,即 $\bar{X}_i = [x_{i1} - \mu_i, x_{i2} - \mu_i, \dots, x_{in_i} - \mu_i], \mu_i$ 为第 $i$ 类样本的均值。对第 $i$ 类样本做PCA分解,保持前 $l_i$ 个主分量以构造 $D_i = [d_1, d_2, \dots, d_{l_i}]$ (这里的 $l_i$ 可通过PCA ratio的值由系统自动选取, $D_i$ 称为第 $i$ 类样本的字典),从而第 $i$ 类中的任一样本 $x$ 均可表示为

$$x = D_i \tilde{s}_i = [D_1, D_2, \dots, D_{i-1}, D_i, D_{i+1}, \dots, D_K] s = D s \quad (5)$$

其中, $\tilde{s}_i$ 是 $x$ 在字典 $D_i = [d_1, d_2, \dots, d_{l_i}]$ 下的系数向量, $s = [0^T, 0^T, \dots, 0^T, \tilde{s}_i^T, 0^T, \dots, 0^T]^T$ 是 $x$ 在整个级联字典 $D = [D_1, D_2, \dots, D_K]$ 下的稀疏表示。 $\tilde{s}_i$ 可以通过最小二乘公式

式(6))求得

$$\tilde{s}_i = (D_i^T D_i)^{-1} D_i^T x = D_i^T x \quad (6)$$

上述公式的约简过程利用了 PCA 分解中各主分量的正交性。图 1 显示了级联字典  $D$  的构造过程。

由上述稀疏学习字典的构造过程可知,每个训练样本都对级联字典  $D$  下的一个稀疏表示。由于任一训练样本  $x$  的稀疏系数  $s$  的计算仅涉及  $D_i$  (式(5)),且由  $D_i$  的列正交性可以快速求出样本  $x$  在正交基  $D_i$  下的系数  $\tilde{s}_i$ ,因此根据式(6)求出稀疏系数  $s$ 。




图 1 级联字典的构造过程

### 3.2 学习稀疏保持结构

由 3.1 节可以看出,级联字典  $D$  在一定程度上描述了数据的几何结构。每一个样本  $x$  的稀疏系数  $s$  显式编码了训练样本的判别信息。为使高维空间中的稀疏表示结构能在投影后的低维空间中得到保持,定义目标函数如下<sup>[25]</sup>:

$$J_s(W) = \min_W \sum_{i=1}^n \|W^T x_i - W^T D s_i\|_2^2 \quad (7)$$

其中,  $s_i$  是样本  $x_i$  在级联字典  $D$  下的稀疏表示系数。式(7)可整理为

$$\begin{aligned} & \sum_{i=1}^n \|W^T x_i - W^T D s_i\|_2^2 \\ &= W^T \left( \sum_{i=1}^n (x_i - D s_i)(x_i - D s_i)^T \right) W \\ &= W^T \left( \sum_{i=1}^n (x_i x_i^T - x_i s_i^T D^T - D s_i x_i^T + D s_i (D s_i)^T) \right) W \\ &= W^T (X X^T - X S^T D^T - D S X^T + D S S^T D^T) W \end{aligned} \quad (8)$$

其中,  $S = [s_1, s_2, \dots, s_n]$ , 从而式(7)可写成

$$J_s(W) = \min_W W^T (X X^T - X S^T D^T - D S X^T + D S S^T D^T) W \quad (9)$$

式(9)等价于求解下述的最大化问题

$$J'_s(W) = \max_W W^T (X S^T D^T + D S X^T - X X^T - D S S^T D^T) W \quad (10)$$

### 3.3 局部类间散度函数

受到流形学习及模式分类的启发,本文通过整合样本的类间信息和局部信息来提高判别学习的效率。由于同类样本会分布在同一个或不同的子流形上,而不同类样本总是分布在不同的子流形上,如何最大程度地隔离不同的子流形对于模式分类问题显得至关重要。基于此,本文构造局部类间散度函数,以描述和量化不同子流形间的分散程度。首先定义局部类间差异度矩阵  $B = [B_{ij}]$ :

$$B_{ij} = \begin{cases} 1 + \exp\left(-\frac{\|x_i - x_j\|_2^2}{\sigma}\right), & \text{如果 } i \in N_{\bar{k}}(j) \text{ 或 } j \in N_{\bar{k}}(i) \\ 0, & \text{其他} \end{cases} \quad (11)$$

其中,  $\sigma$  为训练样本的标准差,  $N_{\bar{k}}(i)$  代表某样本与第  $i$  个样

本  $x_i$  是  $K$  近邻但不同类。由上述定义可以看出,若两个样本距离较远且来自不同类别,则其类间差异度较大,反之亦然。故它们可以将不同类样本投影后更加分离,这就使最大程度地隔离不同的子流形成为可能。

局部类间散度可表示为

$$J_B = \frac{1}{2} \sum_{i,j} B_{ij} \|y_i - y_j\|_2^2 \quad (12)$$

其中,  $y_i = W^T x_i$  为原始数据  $x_i$  经过投影后的目标数据,经过一些代数操作,式(12)可整理为

$$\begin{aligned} J_B &= \frac{1}{2} \sum_{i,j} B_{ij} \|y_i - y_j\|_2^2 \\ &= W^T \left( \sum_{i,j} B_{ij} (x_i - x_j)^T (x_i - x_j) \right) W \\ &= W^T \left( \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n B_{ij} (x_i - x_j)^T (x_i - x_j) \right) W \\ &= W^T \left( \frac{1}{2} \left( \sum_{i=1}^n \sum_{j=1}^n B_{ij} x_i x_i^T - 2 \sum_{i=1}^n \sum_{j=1}^n B_{ij} x_i x_j^T + \sum_{i=1}^n \sum_{j=1}^n B_{ij} x_j x_j^T \right) \right) W \\ &= W^T \left( \sum_{i=1}^n D_i x_i x_i^T - \sum_{i=1}^n \sum_{j=1}^n B_{ij} x_i x_j^T \right) W \\ &= W^T (X D' X^T - X B X^T) W \\ &= W^T X L X^T W \end{aligned} \quad (13)$$

其中,  $D'$  为对角矩阵,其对角线元素  $D'_i = \sum_j B_{ij}$ ,  $L = D' - B$ , 这里称  $L$  为类间拉普拉斯矩阵<sup>[29]</sup>。式(13)描述了不同子流形的差异度即局部类间散度。因此若能够寻求到最优投影向量,即可保证不同子流形的距离越来越大,这更加有利于问题的分类。

### 3.4 SPDL 模型

为获得更好的识别效果,将 3.3 节中用于描述不同子流形的类间差异度信息整合到稀疏保持学习项中。本文将这种进一步利用类别信息的方法称为稀疏保持判别学习 (Sparsity Preserving Discriminative Learning, SPDL)。稀疏保持判别学习 (SPDL) 的目的是在寻求一个有效判别子空间的同时保持数据的稀疏表示结构。根据 3.2 节,最大化稀疏保持正则项  $J'_s(W)$  就能保持稀疏表示结构,故 SPDL 的目标函数如下:

$$\begin{aligned} & \max_W (1-\alpha) J'_s(W) + \alpha J_B(W) \\ &= \max_W (1-\alpha) W^T (D S X^T + X S^T D^T - X X^T - D S S^T D^T) W + \\ & \quad \alpha W^T X L X^T W \end{aligned} \quad (14)$$

其中,  $J'_s(W)$  是 3.2 节中的稀疏保持项;  $J_B(W)$  是 3.3 节中的局部类间散度,即不同子流形的分散程度;  $\alpha$  是控制目标函数中两项平衡的参数。

式(14)可整理为

$$\max_W W^T \left( (1-\alpha) (D S X^T + X S^T D^T - X X^T - D S S^T D^T) + \alpha X L X^T \right) W \quad (15)$$

为避免退化解,加入约束  $W^T X X^T W = 1$ , 并且令

$$\tilde{M} = (1-\alpha) (D S X^T + X S^T D^T - X X^T - D S S^T D^T) + \alpha X L X^T \quad (16)$$

式(14)中的问题可以重写为

$$\max_W \frac{W^T \tilde{M} W}{W^T X X^T W} \quad (17)$$

式(17)最终转化为求解如下的广义特征值问题:

$$\tilde{M}W = \lambda XX^T W \quad (18)$$

故最佳投影矩阵  $W = [\omega_1, \omega_2, \dots, \omega_d]$  可由上述广义特征值问题中最大的  $d$  个特征值对应的特征向量组成。

综上所述,利用 SPDL 算法进行人脸识别的基本步骤如下。

Step 1 为确保  $XX^T$  是非奇异的,首先对原始图像进行 PCA 降维处理,将高维的人脸特征通过转换矩阵投影到低维的 PCA 子空间,并求得投影矩阵  $U_{PCA}$ 。

Step 2 对每类样本的训练集  $X_i$  执行 PCA 分解,求出级联字典  $D$ ; 计算任一样本  $x$  在级联字典  $D$  下的稀疏系数  $s$ , 进而获得稀疏权重矩阵  $S$ 。

Step 3 建立局部类间差异度矩阵  $B$ , 并计算拉普拉斯矩阵  $L = D' - B$ , 进而根据式(16)求解  $\tilde{M}$ 。

Step 4 求解广义特征值问题  $\tilde{M}W = \lambda XX^T W$ , 获得初始投影矩阵  $U^*$ 。

Step 5 计算 SPDL 算法最终的投影矩阵  $U_{SPDL} = U_{PCA} U^*$ , 并将其用于图像特征提取, 得到投影后的图像矩阵为  $Y = U_{SPDL}^T X$ 。

Step 6 利用最近邻分类器对测试图像进行分类。对每一个投影后的测试图像, 比较其与投影后的训练图像间的欧氏距离, 并将其判决为与其最近的图像同类, 进而通过决策的正确与否求出 SPDL 算法的人脸识别率。

#### 4 实验结果与分析

为验证本文所提算法 SPDL 的正确性和有效性, 分别在 Yale<sup>[30]</sup>, ORL<sup>[31]</sup> 和 Extended Yale B<sup>[32]</sup> 人脸库上进行实验, 实验结果与经典算法 PCA, LDA, LPP, NPE, SPP, DLSP 及 DSNPE 进行比较。识别过程通常由以下 3 部分组成: 1) 首先计算出各种算法在同一训练样本集中相应的投影矩阵; 2) 将测试样本投影到所学的投影矩阵, 得到其在低维空间中的特征表示; 3) 使用最近邻分类器对测试样本完成识别。本文的实验环境为 Intel(R) Core(TM) i7-4770K, 3.50GHz CPU, 16.0 GB 内存, Windows 7 操作系统, 实现算法的软件是 Matlab R2013a。



(a) Yale 数据库中第一个人的 11 幅人脸图像



(b) ORL 数据库中第一个人的 10 幅人脸图像



(c) Extended Yale B 数据库中第一个人的 18 幅人脸图像

图 2 3 个人脸数据库的图像样例

Yale 数据库由 15 人组成, 共 165 幅灰度图像, 每人 11 幅; ORL 数据库共有 40 个人的 400 幅人脸图像, 每人 10 幅; Extended Yale B 数据库包含 38 个人的 2414 幅人脸图像, 每人约有 64 幅图像。这些图像包括了姿态、光照和表情的差

异。为有效计算, 所有图像都根据眼睛的位置进行配准, 然后被缩放为大小  $32 \times 32$  的图像, 图 2 展示了上述 3 个人脸数据库的图像样例。后续实验中, 每幅图像都被归一化为单位范数。

在本实验中, 每人随机选取一半图像用于训练 (Yale, ORL 和 Extended Yale B 每人分别随机选取 6、5 和 30 幅图像), 其余图像用于测试, 重复 50 次, 最后取平均值作为识别结果。PCA 和 LDA 没有模型参数, SPP<sup>[25]</sup> 中的参数  $\epsilon$  设为 0.05, LPP 和 NPE 中的邻域模式设为“Supervised”, 权值模式设为“Cosin”。SPDL 中的参数  $\alpha$  通过 10 倍交叉验证从集合  $S = \{0.1, 0.2, \dots, 0.9\}$  中选择。对于 Yale, ORL 及 Extended Yale B, 相应的  $\alpha$  分别设置为 0.6、0.3 和 0.8。因人脸向量空间的维数远大于训练样本的个数, LPP, NPE, DLSP, DSNPE 及 SPDL 等方法都涉及 PCA 预处理阶段, 即将训练样本集投影到主分量生成的子空间上。由于 Yale 和 ORL 数据库规模较小, 设置 PCA ratio 为 1; 而针对规模较大的 Extended Yale B 数据库, 为能在合理的时间内得到实验结果, 设置 PCA ratio 为 0.98。

特征提取算法的识别率通常随维数的大小而变化。图 3 显示了 PCA, LDA, LPP, NPE, SPP, DLSP, DSNPE 和 SPDL 在 3 个测试数据库上的识别率随维数的变化情况。各种特征提取算法在 3 个库上的最高识别率及对应方差如表 1 所列。

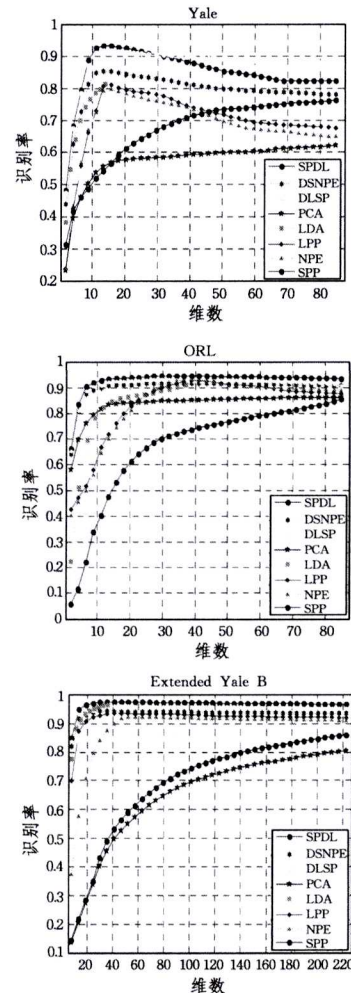


图 3 各种算法在 Yale, ORL 和 Extended Yale B 上识别率随维数的变化情况

表1 各种方法的最优识别率及对应标准差

算法	PCA	LDA	LPP	NPE	SPP	DSNPE	DLSP	SPDL
Yale	62.41(±3.83)	81.32(±4.56)	81.39(±4.56)	79.91(±5.14)	76.53(±4.23)	85.45(±4.51)	92.68(±3.29)	93.39(±3.36)
ORL	86.26(±2.13)	92.31(±4.56)	92.89(±3.56)	93.31(±2.18)	86.04(±3.16)	91.78(±2.75)	93.72(±3.02)	94.59(±3.29)
E-Yale B	80.41(±1.63)	96.47(±4.56)	94.85(±3.41)	92.81(±4.78)	85.56(±2.17)	94.29(±2.25)	96.37(±3.26)	97.56(±3.48)

通过图3可以看出,SPDL,DSNPE及DLSP的识别率比其他对比算法都高,这是因为3种算法在保持数据稀疏表示结构的同时,均加入了判别信息,从而特征提取效率和分类能力较突出。其中,本文提出的SPDL的识别率与DLSP的识别率接近,均稍优于DSNPE算法。另外,3种算法在初始阶段的识别率随维数的增加比其他方法变化得更快,这是因为它们在学习稀疏表示结构和计算局部类间散度时都用到了类标信息。这表明相比于其他方法,3种算法在一个比较低维的子空间中获得了更好的判别性能,这有利于降低计算成本及节约维数约简后的存储空间。

此外,本实验还对SPDL,SPP,DSNPE及DLSP学习嵌入函数的运行时间做了比较。它们在每个测试数据库上学习嵌入函数所需的平均时间,如表2所列。从实验结果看,SPDL的执行时间比其他3种算法少得多,特别是在Extended Yale B等较大规模数据库上。这是因为SPDL在学习稀疏表示结构时只需做K个PCA分解和n个最小二乘法(其算法复杂度为 $O(m^2 \sum_{i=1}^K l_i + m \sum_{i=1}^K n_i l_i)$ ),但SPP在学习稀疏表示结构时需要求解n个耗时的 $l_1$ 范数优化问题(其算法复杂度为 $O(n^4)^{[25]}$ ),而DLSP及DSNPE的计算复杂度 $^{[27,28]}$ 均高于 $O(n^3)$ ,一般来讲, $n_i \ll n, l_i \ll n$ 且 $K \ll n$ ,故SPDL的计算效率比SPP,DLSP及DSNPE更高。

表2 SPDL和SPP学习嵌入函数运行时间比较

算法	SPP	DLSP	DSNPE	SPDL
Yale	2.1609	3.7596	1.2337	0.5469
ORL	8.4467	12.2618	4.8593	0.5127
Extended Yale B	190.0017	285.4391	102.7285	2.8435

最后,本文研究了SPDL算法中局部类间散度项和稀疏保持正则项的控制参数 $\alpha$ 的鲁棒性问题。在Yale,ORL和Extended Yale B数据库上, $\alpha$ 对SPDL的性能影响如图4所示。从实验结果可知,SPDL的识别性能随 $\alpha$ 的变化影响较小,所以其对控制参数 $\alpha$ 是鲁棒的。




图4 在Yale,ORL和Extended Yale B数据库上参数 $\alpha$ 对SPDL识别性能的影响

**结束语** 本文提出一种基于流形学习和稀疏约束的快速特征提取算法SPDL,其目的是在寻求最佳投影矩阵的同时保持数据的稀疏表示结构。具体来讲,SPDL首先通过逐类PCA构造级联字典,并基于该字典通过最小二乘法快速学习稀疏保持结构;其次构造用于描述不同子流形距离的局部类间散度函数;然后整合所学习到的稀疏表示信息和局部类间散度信息以达到既考虑判别效率又保持稀疏表示结构的目的;所提算法最终转化为一个求解广义特征值问题。在一些公共人脸数据库上的实验证明了所提算法的优越性能。

### 参考文献

- [1] Kumar K B, Venkataraman D. Object Detection Using Robust Image Features [M]// Artificial Intelligence and Evolutionary Algorithms in Engineering Systems, Springer India, 2015: 285-295
- [2] Zhang Wen, Tang Xi-jin, Yoshida T. TESC: An approach to Text classification using Semi-supervised Clustering [J]. Knowledge-Based Systems, 2015, 75: 152-160
- [3] Zhao Xue-yi, Li Xi, Zhang Zhong-fei. Multimedia Retrieval via Deep Learning to Rank [J]. IEEE Signal Processing Letters, 2015, 22(9): 1487-1491
- [4] Li Cheng-husan, Ho Hsin-hua, Kuo Bor-chen, et al. A Semi-supervised Feature Extraction based on Supervised and Fuzzy-based Linear Discriminant Analysis for Hyperspectral Image Classification [J]. Applied Mathematics & Information Sciences, 2015, 9(1L): 81-87
- [5] Zhang De-hai, Ding Da, Li Jin, et al. PCA Based Extracting Feature Using Fast Fourier Transform for Facial Expression Recognition [M]// Transactions on Engineering Technologies, Springer Netherlands, 2015: 413-424
- [6] Lai Yi-qi. Rotation Moment Invariant Feature Extraction Techniques for Image Matching [J]. Applied Mechanics and Materials, 2014, 721: 775-778
- [7] Wold S, Esbensen K, Geladi P. Principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1-3): 37-52
- [8] Altman E I, Marco G, Varetto F. Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks [J]. Journal of Banking and Finance, 1994, 18(3): 505-529
- [9] Tenenbaum J, Silva V, Langford J. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2322
- [10] Mikhail B, Partha N. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396
- [11] Roweis Sam T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326

- [2] Suma E A, Lange B, Rizzo A S, et al. Faast: The flexible action and articulated skeleton toolkit[C]//2011 IEEE Virtual Reality Conference (VR). IEEE,2011:247-248
- [3] Kar A. Skeletal tracking using microsoft kinect [J]. *Methodology*,2010,1:1-11
- [4] Ren Z, Meng J, Yuan J, et al. Robust hand gesture recognition with kinect sensor[C]//Proceedings of the 19th ACM international conference on Multimedia. ACM,2011:759-760
- [5] Ren Z, Yuan J, Zhang Z. Robust hand gesture recognition based on finger-earth mover's distance with a commodity depth camera[C]//Proceedings of the 19th ACM International Conference on Multimedia. ACM,2011:1093-1096
- [6] Kleinsmith A, Bianchi-Berthouze N. Affective body expression perception and recognition: A survey[J]. *IEEE Transactions on Affective Computing*,2013,4(1):15-33
- [7] Li W, Mian A S, Krishna A, et al. Using kinect for face recognition under varying poses, expressions, illumination and disguise [C]//2013 IEEE Workshop on Applications of Computer Vision (WACV). IEEE,2013:186-192
- [8] Izadi S, Kim D, Hilliges O, et al. Kinect Fusion: real-time 3D reconstruction and interaction using a moving depth camera[C]//Proceedings of the 24th Annual ACM Symposium on User Interface Software and Technology. ACM,2011:559-568
- [9] Tong J, Zhou J, Liu L, et al. Scanning 3d full human bodies using kinects[J]. *IEEE Transactions on Visualization and Computer Graphics*,2012,18(4):643-650
- [10] Shen C H, Huang S S, Fu H, et al. Adaptive partitioning of urban facades[J]. *ACM Transactions on Graphics (TOG)*, ACM,2011,30(6):184
- [11] Shen C H, Fu H, Chen K, et al. Structure recovery by part assembly[J]. *ACM Transactions on Graphics (TOG)*,2012,31(6):180
- [12] Yan F, Sharf A, Lin W, et al. Proactive 3D scanning of inaccessible parts[J]. *ACM Transactions on Graphics (TOG)*,2014,33(4):157
- [13] Newcombe R A, Davison A J, Izadi S, et al. KinectFusion: Real-time dense surface mapping and tracking[C]//2011 10th IEEE International Symposium on Mixed and Augmented Reality (ISMAR). IEEE,2011:127-136
- [14] Kazhdan M, Bolitho M, Hoppe H. Poisson surface reconstruction[C]//Proceedings of the Fourth Eurographics Symposium on Geometry Processing. 2006
- [15] Kazhdan M, Hoppe H. Screened poisson surface reconstruction [J]. *ACM Transactions on Graphics (TOG)*,2013,32(3):29
- 
- (上接第 281 页)
- [12] He Xiao-fei, Niyogi Partha. Locality preserving projections [C]//Proceedings of the Advances in Neural Information Processing Systems (NIPS). 2003,16:585-591
- [13] He Xiao-fei, Cai Deng, Yan Shui-cheng, et al. Neighborhood preserving embedding [C]//Tenth IEEE International Conference on IEEE(ICCV 2005). 2005,2:1208-1213
- [14] Yan Shui-cheng, Xu Dong, Zhang Ben-yu, et al. Graph embedding: a general framework for dimensionality reduction [J]. *IEEE Trans. Pattern Anal. Mach. Intell.*,2007,29(1):40-51
- [15] Shrivastava A, Patel V M, Chellappa R. Multiple kernel learning for sparse representation-based classification [J]. *IEEE Transactions on Image Processing*,2014,23(7):3013-3024
- [16] Bai Zuo, Huang Guang-bin, Wang Dan-wei, et al. Sparse extreme learning machine for classification [J]. *IEEE Transactions on Cybernetics*,2014,44(10):1858-1870
- [17] Hui Kang-hua, Li Chun-li, Zhang Lei. Sparse neighbor representation for classification [J]. *Pattern Recognition Letters*,2012,33(5):661-669
- [18] Feng Zhi-zhao, Yang Meng, Zhang Lei, et al. Joint discriminative dimensionality reduction and dictionary learning for face recognition [J]. *Pattern Recognition*,2013,46(8):2134-2143
- [19] Yang Meng, Zhang Lei, Yang Jian, et al. Regularized robust coding for face recognition [J]. *IEEE Transactions on Image Processing*,2013,22(5):1753-1766
- [20] Shao Ming, Ma Ming-bo, Fu Yun. Sparse manifold subspace learning [M]//Low-Rank and Sparse Modeling for Visual Analysis. Springer,2014:117-132
- [21] Zhang Sheng-ping, Yao Hong-xun, Sun Xin, et al. Sparse coding based visual tracking: review and experimental comparison [J]. *Pattern Recognition*,2013,46(7):1772-1788
- [22] Zhang Sheng-ping, Yao Hong-xun, Zhou Hui-yu, et al. Robust visual tracking based on online learning sparse representation [J]. *Neurocomputing*,2013,100(1):31-40
- [23] Wright J, Yang A, Sastry S, et al. Robust face recognition via sparse representation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2009,31(2):210-227
- [24] Guan Nai-yang, Tao Da-cheng, Luo Zhi-gang, et al. Mahnmf: Manhattan Non-negative Matrix Factorization [J]. *Journal of Machine Learning Research*,2012,arXiv:1207.3438
- [25] Qiao Li-shan, Chen Song-can, Tan Xiao-yang. Sparsity preserving projections with applications to face recognition[J]. *Pattern Recognition*,2010,43(1):331-341
- [26] Qiao Li-shan, Chen Song-can, Tan Xiao-yang. Sparsity preserving discriminant analysis for single training image face recognition [J]. *Pattern Recognition Letters*,2010,31(5):422-429
- [27] Zang Fei, Zhang Jiang-she. Discriminative learning by sparse representation for classification [J]. *Neurocomputing*,2011,74(12):2176-2183
- [28] Gui Jie, Sun Zhe-nan, Jia Wei, et al. Discriminant sparse neighborhood preserving embedding for face recognition [J]. *Pattern Recognition*,2012,45(8):2884-2893
- [29] Lou Song-jiang, Zhang Guo-yin, Pan Hai-wei. Supervised laplacian discriminant analysis for small sample size problem with its application to face recognition [J]. *Journal of Computer Research and Development*,2012,49(8):1730-1737
- [30] Belhumeur P N, Hespanha J, Kriegman D. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,1997,19(7):711-720
- [31] Samaria F, Harter A. Parameterisation of a stochastic model for human face identification[C]//Second IEEE Workshop on Applications of Computer Vision. Sarasota,1994:138-142
- [32] Lee K, Ho J, Kriegman D. Acquiring linear subspaces for face recognition under variable lighting [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2005,27(5):684-698