

基于面向分类准则的维数约简及其在 人脸识别中的应用

殷飞 焦李成

(西安电子科技大学智能感知与图像理解教育部重点实验室 西安 710071)

摘要 针对高维数据导致的维数灾难问题,提出了一种基于面向分类准则的维数约简方法。所提准则使每个训练样本在特征空间中与同类样本尽可能接近,而与异类样本尽可能疏远。首先对每个训练样本定义同类样本加权平均距离和异类样本加权平均距离。然后基于上述两个概念分别定义总体同类距离和总体异类距离。以最小化总体同类距离和最大化总体异类距离为目的提出了面向分类的准则(Classification Oriented Criterion, COC)。最后,基于面向分类的准则推导出了—种新的维数约简方法。在公共人脸数据库 ORL 和 Yale 上的实验表明所提方法性能优于有代表性的维数约简方法。

关键词 维数约简,总体同类距离,总体异类距离,面向分类的准则,人脸识别

中图法分类号 TP391.4 **文献标识码** A

Classification Oriented Criterion Based Dimensionality Reduction and its Application in Face Recognition

YIN Fei JIAO Li-cheng

(Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education of China,
Xidian University, Xi'an 710071, China)

Abstract To tackle the problem of the curse of dimensionality caused by high dimensional data, a classification oriented criterion based dimensionality reduction method was presented. The proposed criterion aims at making each training sample and samples from the same class as close as possible in the feature space and making each training sample and samples from the different classes as distant as possible in the feature space. First, for each training sample, weighted average distance of samples from the same class and weighted average distance of samples from different classes were defined. Then, based on these two concepts, total distance of samples from the same class and total distance of samples from different classes were defined. After that, Classification Oriented Criterion (COC) was proposed, which aims at minimizing the total distance of samples from the same class and maximizing the total distance of samples from different classes. Finally, a novel dimensionality reduction method based on COC was presented. The experiments on publicly available face databases ORL and Yale demonstrate that the proposed method outperforms representative dimensionality reduction methods.

Keywords Dimensionality reduction, Total distance of samples from the same class, Total distance of samples from different classes, Classification oriented criterion, Face recognition

1 引言

在各种科学研究领域,如人脸识别、文本分类及信息检索,人们经常要处理非常高维的数据。而高维数据通常会带来如下问题:(1)高计算复杂度会限制很多方法的实际应用;(2)当样本数小于数据维数时,模型估计的性能往往会变差(小样本问题)。这些问题在机器学习和数据挖掘中统称“维数灾难”^[1]。维数约简通常被用来有效处理这些问题。迄今为止,研究人员已经提出了多种维数约简方法。有代表性的维数约简方法主要有:主分量分析(Principal Component

Analysis, PCA)^[2]、线性判别分析(Linear Discriminant Analysis, LDA)^[3]、局部保持投影(Locality Preserving Projections, LPP)^[4]、邻域保持嵌入(Neighborhood Preserving Embedding, NPE)^[5]、最大边界准则(Maximum Marginal Criterion, MMC)^[6]和边界费舍尔分析(Marginal Fisher Analysis, MFA)^[7,8]。最近,稀疏表示的思想^[9-11]也被引入到维数约简的领域,学者们提出了多种基于稀疏表示的维数约简方法,主要包括稀疏保持投影(Sparsity Preserving Projections, SPP)^[12]、基于稀疏表示投影的判别学习(Discriminative Learning by Sparse Representation Projections, DLSP)^[13]和

到稿日期:2013-06-27 返修日期:2013-11-25 本文受国家重点基础研究发展计划(2013CB329402),国家自然科学基金(61072106, 61173090, 61072108, 61303034),教育部长江学者和创新团队发展计划(IRT1170)和基本科研业务费(K5051303011)资助。

殷飞(1984—),男,博士生,主要研究方向为模式识别、图像处理、机器学习, E-mail: yinfei701@163.com; 焦李成(1959—),男,教授,博士生导师,主要研究方向为模式识别、智能信息处理。

快速 Fisher 稀疏保持投影 (Fast Fisher Sparsity Preserving Projections, FFSPP)^[14] 等。

PCA 以最大化低维投影数据的方差为目的, 其已被广泛应用于各种科学和工程领域。经典的人脸识别方法特征脸方法 (Eigenface method)^[15] 就是 PCA 在人脸识别中的应用。PCA 可以很好地用于数据表示, 但由于没有考虑类标信息, 对于分类问题并不是一个很可靠的方法。LDA 以同时最大化类间散度和最小化类内散度为目的。由于利用了类标信息, 对于分类问题 LDA 往往比 PCA 更有效。人脸识别中的费舍尔脸方法 (Fisherface method)^[16] 就是基于 LDA 的。尽管很有效, 但是 LDA 也存在如下问题: (1) 最多只能提取 $K-1$ 维特征 (K 为样本类别数); (2) 面临小样本问题; (3) 只在每类数据都来自一个高斯分布时才最优^[7]。LPP 和 NPE 都属于基于局部邻域结构^[17] 的方法。LPP 寻找一个能够保持局部邻域结构的嵌入, 以便得到一个能最好拟合潜在人脸流形的人脸子空间。LPP 的缺点是需要人工选择邻域大小参数和边权值参数, 而其性能对这些参数比较敏感。NPE 也以保持局部邻域结构为目的。与 LPP 的不同在于, NPE 通过局部最小二乘近似来获得边权值矩阵, 而 LPP 通过直接定义来获得边权值矩阵, 但 NPE 仍然需要人工选择邻域大小参数。LPP 实际上是对经典流形学习算法拉普拉斯特征映射 (Laplacian Eigenmaps, LE)^[18] 的最优线性近似, NPE 则是经典流形学习算法局部线性嵌入 (Locally Linear Embedding, LLE)^[19] 的线性化版本。MMC 将 LDA 的判别准则由商准则修改为差准则^[20]。由于不依赖于类内散度矩阵的非奇异性, MMC 能够克服 LDA 的小样本问题。另外, 通过引入合适的约束, 也可以基于 MMC 导出 LDA。MFA 首先定义一个内在图 (intrinsic graph) 和一个惩罚图 (penalty graph)。然后基于内在图定义类内紧致性 (intra-class compactness), 基于惩罚图定义类间可分性 (inter-class separability)。最后基于图嵌入框架导出 MFA 算法。MFA 需要针对内在图和惩罚图分别人工选择邻域大小参数。

本文提出了一种新的维数约简准则: 面向分类的准则 (Classification Oriented Criterion, COC), 并基于所提准则设计了一种新的维数约简方法。COC 的目的是使每一个训练样本在特征空间中与同类样本越近越好, 与异类样本越远越好。该准则使得原始数据在特征空间中更有利于分类, 故称为面向分类的准则。首先对每一个训练样本定义同类样本加权平均距离和异类样本加权平均距离。然后基于上述两个概念分别定义总体同类距离和总体异类距离。以最小化总体同类距离和最大化总体异类距离为目的定义面向分类的维数约简准则。最后, 基于所提维数约简准则 COC 推导出了—种新的维数约简方法。在公共人脸数据库上的实验表明所提方法性能优于有代表性的维数约简方法。

2 面向分类的维数约简准则

本小节详细讲述所提出的面向分类的维数约简准则。已知训练样本集为 $\{x_i\}_{i=1}^n$, 其中 $x_i \in R^m$ 。令 $X = [x_1, x_2, \dots, x_n] \in R^{m \times n}$ 表示包含所有样本的数据矩阵。假设样本来自 K 类 $\{C_1, C_2, \dots, C_K\}$, 令 $X = [X_1, X_2, \dots, X_K]$, 其中 $X_i \in R^{m \times n_i}$ 包含 C_i 类中的样本, n_i 是 C_i 类中的样本数。定义类标函数 $l(x_i)$, 其值为训练样本 x_i 的类标。假定原数据矩阵 X 在特

征空间的低维表示 $Y = [y_1, y_2, \dots, y_n] \in R^{d \times n}$, d 表示低维空间的维数。首先定义样本 x_i 在特征空间的对应点 y_i 的同类样本加权平均距离和异类样本加权平均距离。

定义 1 样本 x_i 在特征空间的对应点 y_i 的同类样本加权平均距离定义为

$$dw_1(y_i) = \frac{\sum_{j: l(x_j)=l(x_i), j \neq i} w_{ij} \|y_i - y_j\|^2}{\sum_{j: l(x_j)=l(x_i), j \neq i} w_{ij}} \quad (1)$$

其中

$$w_{ij} = \exp\left(\frac{-\|x_i - x_j\|^2}{h}\right) \quad (2)$$

w_{ij} 是一个相似度函数, 用来度量样本 x_i 和 x_j 的相似度, 其中 $h \in R$ 为热核参数。定义的加权平均距离对 x_i 与距 x_i 较近的样本在特征空间的距离赋以较大的权值, 对 x_i 与距 x_i 较远的样本在特征空间的距离赋以较小的权值。

定义 1 中的同类样本加权平均距离 $dw_1(y_i)$ 能够度量样本 x_i 在特征空间中的对应点 y_i 与其他同类样本的聚集程度。 $dw_1(y_i)$ 越小, y_i 与其他同类样本的聚集性越好; $dw_1(y_i)$ 越大, y_i 与其他同类样本的聚集性越差。为了有利于维数约简后的分类, $dw_1(y_i)$ 越小越好。

定义 2 样本 x_i 在特征空间的对应点 y_i 的异类样本加权平均距离定义为

$$dw_2(y_i) = \frac{\sum_{k: l(x_k) \neq l(x_i)} w_{ik} \|y_i - y_k\|^2}{\sum_{k: l(x_k) \neq l(x_i)} w_{ik}} \quad (3)$$

其中, w_{ij} 的定义如式 (2) 所示。

定义 2 中的异类样本加权平均距离 $dw_2(y_i)$ 能够度量样本 x_i 在特征空间中的对应点 y_i 与异类样本的分散程度。 $dw_2(y_i)$ 越小, y_i 与异类样本的分散性越差; $dw_2(y_i)$ 越大, y_i 与异类样本的分散性越好。为了有利于维数约简后的分类, $dw_2(y_i)$ 越大越好。

基于定义 1 和定义 2, 定义如下的总体同类距离和总体异类距离。

定义 3 总体同类距离定义为

$$dw_{1-t} = \sum_{i=1}^n dw_1(y_i) = \sum_{i=1}^n \frac{\sum_{j: l(x_j)=l(x_i), j \neq i} w_{ij} \|y_i - y_j\|^2}{\sum_{j: l(x_j)=l(x_i), j \neq i} w_{ij}} \quad (4)$$

定义 3 中的总体同类距离 dw_{1-t} 能够度量特征空间中所有样本总体聚集程度。 dw_{1-t} 越小, 特征空间中所有样本总体聚集性越好; dw_{1-t} 越大, 特征空间中所有样本总体聚集性越差。为了有利于维数约简后的分类, 总体同类距离 dw_{1-t} 越小越好。

定义 4 总体异类距离定义为

$$dw_{2-t} = \sum_{i=1}^n dw_2(y_i) = \sum_{i=1}^n \frac{\sum_{k: l(x_k) \neq l(x_i)} w_{ik} \|y_i - y_k\|^2}{\sum_{k: l(x_k) \neq l(x_i)} w_{ik}} \quad (5)$$

定义 4 中的总体异类距离 dw_{2-t} 能够度量特征空间中所有样本与异类样本的总体分散程度。 dw_{2-t} 越小, 特征空间中所有样本与异类样本的总体分散性越差; dw_{2-t} 越大, 特征空间中所有样本与异类样本的总体分散性越好。为了有利于维数约简后的分类, 总体异类距离 dw_{2-t} 越大越好。

综上所述, 为了有利于维数约简后的分类, 总体同类距离 dw_{1-t} 越小越好, 而总体异类距离 dw_{2-t} 越大越好。故以最小化总体同类距离和最大化总体异类距离为目的, 定义如下的面

向分类的维数约简准则。


定义 5 面向分类的准则(Classification Oriented Criterion, COC)定义为

$$J = \frac{dw_{2_t}}{dw_{1_t}} \quad (6)$$

式(6)中的 J 越大,数据在特征空间中的分布越有利于分类,所以要设计的维数约简方法应使 J 在特征空间越大越好。

3 基于面向分类的准则的维数约简

本节基于第 2 节提出的 COC 准则设计一种新的维数约简方法。在做维数约简时,需要寻找一个从数据空间到特征空间的映射以使 COC 准则 J 在特征空间最大化,也就是使总体同类距离 dw_{1_t} 尽可能小,而总体异类距离 dw_{2_t} 尽可能大,图 1 展示了这一点。这里考虑线性映射 $y = P^T x$, 其中 $P \in R^{m \times d}$ 表示投影矩阵, m 是原数据空间的维数, d 是投影后的特征空间的维数。这里需要寻找一个最优投影矩阵 P , 将其原始数据映射到低维特征空间后使 COC 准则 J 在特征空间最大化。



(a) 原始数据空间中的数据分布 (b) 基于 COC 准则做维数约简后特征空间中的数据分布

图 1 COC 准则的直观展示,圆形表示一类,三角形表示另一类

原始数据通过投影矩阵 P 映射后在低维特征空间的总体同类距离为

$$\begin{aligned} dw_{1_t} &= \frac{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij} \|y_i - y_j\|^2}{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij}} \\ &= \frac{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij} (y_i - y_j)(y_i - y_j)^T}{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij}} \\ &= \frac{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij} (P^T x_i - P^T x_j)(P^T x_i - P^T x_j)^T}{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij}} \\ &= \frac{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij} (x_i - x_j)(x_i - x_j)^T}{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij}} P \\ &= \text{tr}(P^T C P) \end{aligned} \quad (7)$$

其中, $\text{tr}(\cdot)$ 是迹函数,

$$C = \frac{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij} (x_i - x_j)(x_i - x_j)^T}{\sum_{i=1}^n \sum_{j, l(x_j)=l(x_i), j \neq i} w_{ij}} \quad (8)$$

C 称为总体聚集性矩阵。

原始数据通过投影矩阵 P 映射后在低维特征空间的总体异类距离为

$$\begin{aligned} dw_{2_t} &= \frac{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik} \|y_i - y_k\|^2}{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik}} \end{aligned}$$

$$\begin{aligned} &= \text{tr} \left(\frac{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik} (y_i - y_k)(y_i - y_k)^T}{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik}} \right) \\ &= \text{tr} \left(\frac{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik} (P^T x_i - P^T x_k)(P^T x_i - P^T x_k)^T}{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik}} \right) \\ &= \text{tr} \left[P^T \left(\frac{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik} (x_i - x_k)(x_i - x_k)^T}{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik}} \right) P \right] \\ &= \text{tr}(P^T S P) \end{aligned} \quad (9)$$

其中

$$S = \frac{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik} (x_i - x_k)(x_i - x_k)^T}{\sum_{i=1}^n \sum_{k, l(x_k) \neq l(x_i)} w_{ik}} \quad (10)$$

S 称为总体分散性矩阵。

因此,原始数据通过投影矩阵 P 映射后在低维特征空间的 COC 准则可写为

$$J = \frac{dw_{2_t}}{dw_{1_t}} = \frac{\text{tr}(P^T S P)}{\text{tr}(P^T C P)} \quad (11)$$

那么,基于 COC 准则的维数约简寻找一个最优投影矩阵 P 以使 COC 准则最大化,故需求解如下优化问题:

$$\max_P J(P) = \frac{\text{tr}(P^T S P)}{\text{tr}(P^T C P)} \quad (12)$$

式(12)可以通过如下的广义特征值问题来求解^[21]:

$$S p = \eta C p \quad (13)$$

其中, η 和 p 分别表示上述广义特征值问题的特征值和特征向量。最优投影矩阵 P 由上述广义特征值问题的最大 d 个特征值所对应的特征向量组成。令问题式(13)的最大 d 个特征值 $\eta_1 \geq \eta_2 \geq \dots \geq \eta_d$ 对应的特征向量为 p_1, p_2, \dots, p_d , 那么最优投影矩阵 $P = [p_1, p_2, \dots, p_d]$ 。基于面向分类的准则的维数约简方法被总结在算法 1 中。

算法 1 基于面向分类的准则的维数约简(COC)

输入: 训练样本集 $X = [x_1, x_2, \dots, x_n] \in R^{m \times n}$, 热核参数 h 。

输出: 投影矩阵 P 。

步骤 1 根据式(8)和式(2)计算矩阵 C 。

步骤 2 根据式(10)和式(2)计算矩阵 S 。

步骤 3 求解式(13)中的广义特征值问题,得到所求投影矩阵 $P = [p_1, p_2, \dots, p_d]$, 其中 p_1, p_2, \dots, p_d 是式(13)的最大 d 个特征值所对应的特征向量。

步骤 4 停止。

4 实验与结果分析

为验证本文算法的性能,分别在公共人脸数据库 ORL 和 Yale 上进行实验,并与有代表性的维数约简方法 PCA、LDA、LPP、NPE、MMC 和 MFA 进行对比分析。实验在做维数约简后使用最近邻分类器完成分类。本文的实验环境为: Pentium4 双核 3.2GHz CPU, 3GB 内存, 实现算法的软件是 Matlab7.0.1。

ORL^[22]人脸数据库包含 40 个人的 400 幅人脸图像,每人 10 幅。这些人脸图像是在不同时间、不同光照条件和不同人脸表情下获得的。另外人脸姿态有一定程度的侧向移动。所有图像根据眼睛的位置进行配准,然后每幅图像被缩放为大小 32×32 的图像。该数据库的一些样例图像如图 2(a) 所示。

Yale^[16]人脸数据库包含 15 个人的 165 幅人脸图像,每

人 11 幅。每人的每幅图像均是从如下不同表情或配置中获得:中心光照、配戴眼镜、高兴、左边光照、不戴眼镜、正常表情、右边光照、沮丧、困倦、惊讶、眨眼。所有图像根据眼睛的位置进行配准,然后每幅图像被缩放为大小 32×32 的图像。该数据库的一些样例图像如图 2(b)所示。



图 2

对每个数据库中每类人脸分别随机选取 2 幅、3 幅、4 幅图像作为训练集(分别简称为 2train、3train、4train),剩下的人脸图像作为测试集。在实验中,得到平均 20 次随机训练/测试划分的实验结果,记录平均分类精度和标准差。PCA、LDA 和 MMC 没有需要设定的参数。本文实验使用有监督 LPP 和 NPE,其参数设置分别使用文献[5,23]中的方法。MFA 的参数设置使用文献[7]中的方法。COC 的热核参数 h 使用 5 倍交叉验证从 $\{4^{-4}, 4^{-3}, 4^{-2}, 4^{-1}, 4^0, 4^1, 4^2, 4^3, 4^4\}$ 中选取。

图 3 和图 4 分别给出了 ORL 和 Yale 数据库上不同方法在不同特征维数下的识别率曲线。需要指出的是,由于 LDA 最多只能提取 $K-1$ 维特征,图 3 和图 4 中 LDA 对应的曲线分别只画到第 39 维和第 14 维。根据图 3 和图 4 中的实验结果,可以得到如下结论:

(1)PCA 的识别率明显低于其他方法,这是因为 PCA 是一种无监督方法,并没有利用类标信息,而其他比较方法都利用了类标信息。

(2)对于 ORL 数据库,当特征维数超过 30 时,在不同训练集大小下,COC 的识别率都一致高于其他方法。这说明 COC 准则是一个判别性较强的维数约简准则。

(3)对于 Yale 数据库,当特征维数大于 12 时,在不同训练集大小下,COC 的识别率都一致高于其他方法。这进一步说明 COC 准则是一个判别性较强的维数约简准则。

(4)在开始阶段,随着投影维数的增加,COC 的识别率快速增加,而当投影维数增加到某个点后,COC 的识别率不再增加,甚至有所下降。如何决定最优投影维数仍然是一个公开问题。




图 3 ORL 人脸数据库上,不同算法识别率随特征维数的变化




图 4 Yale 人脸数据库上,不同算法识别率随特征维数的变化

表 1 和表 2 分别给出了不同方法在 ORL 和 Yale 数据库上的最优识别率及对应的特征维数。根据表 1 和表 2 中的实验结果,可以得到如下结论:

(1)PCA 达到最优识别率所需的特征维数最多,MMC 次之,而 LDA、LPP、NPE、MFA 和 COC 达到最优识别率所需的特征维数相对较少。

(2)所提方法 COC 在 ORL 和 Yale 数据库上的各种训练集大小下识别率都一致地高于其他对比方法,这进一步验证了所提 COC 准则更有利于维数约简后的分类。

(3)在大多数情况下,相对 20 次随机训练/测试划分,COC 识别率的标准差最小。这表明 COC 相对随机训练/测试划分的稳定性最好。

表 1 各种算法在 ORL 数据库上的最优识别率(均值±标准差,%)及对应的特征维数

算法	2train	3train	4train
PCA	67.16±2.59(79)	75.84±3.70(119)	82.12±2.71(159)
LDA	72.48±2.91(24)	82.84±3.12(39)	89.67±2.17(39)
LPP	78.41±2.27(39)	86.66±1.96(39)	90.67±1.82(39)
NPE	78.59±2.78(39)	86.50±2.09(39)	90.56±1.65(39)
MMC	72.39±3.72(49)	83.36±3.51(79)	90.29±2.38(56)
MFA	73.45±2.97(30)	85.23±3.53(28)	91.29±2.18(23)
COC	81.27±2.05(50)	88.96±1.94(54)	93.54±1.56(38)

表 2 各种算法在 Yale 数据库上的最优识别率(均值±标准差,%)及对应的特征维数

算法	2train	3train	4train
PCA	43.93±2.73(29)	49.00±3.49(43)	52.19±3.72(59)
LDA	53.59±6.01(14)	64.92±5.17(14)	72.29±3.64(14)
LPP	57.89±4.49(14)	68.21±4.46(15)	74.76±4.64(14)
NPE	56.41±5.02(14)	68.17±4.98(14)	74.62±3.51(14)
MMC	54.08±4.08(19)	66.98±5.09(22)	72.95±3.84(40)
MFA	54.89±4.74(14)	69.29±4.35(14)	76.14±3.99(14)
COC	58.85±2.78(17)	72.21±3.33(15)	78.95±3.47(15)

本文所提方法 COC 有一个热核参数 h 。这里考察 COC 在 ORL 和 Yale 数据库上的各种训练集大小下对热核参数 h 的敏感性,实验结果如图 5 和图 6 所示。从图 5 和图 6 可以看出,在两个测试数据库的各种训练集大小下,COC 的识别率随参数的变化都很小,故 COC 对参数 h 有很好的鲁棒性。




图5 ORL人脸数据库上,COC算法识别率随热核参数 h 的变化




图6 Yale人脸数据库上,COC算法识别率随热核参数 h 的变化

结束语 本文以原始数据在特征空间中更有利于分类为目的,定义了一种新的维数约简准则:面向分类的准则(COC)。基于所提准则,推导出了一种新的维数约简方法。在公共人脸数据库 ORL 和 Yale 上的实验表明,所提方法性能优于有代表性的维数约简方法。参数分析表明,所提方法对热核参数 h 具有很好的鲁棒性。进一步的研究方向是使用核方法推导出所提方法的非线性版本,以提高其处理非线性问题的能力。

参 考 文 献

[1] Bishop C M. Pattern Recognition and Machine Learning [M]. New York; Springer, 2006
 [2] Jolliffe I T. Principal Component Analysis [M]. New York; Springer, 1986
 [3] Fukunaga K. Introduction to Statistical Pattern Recognition (Second edition)[M]. New York; Academic Press, 1990
 [4] He X, Niyogi P. Locality preserving projections [C]// Proceedings of the Advances in Neural Information Processing Systems (NIPS) 16. 2003; 585-591
 [5] He X, Cai D, Yan S, et al. Neighborhood preserving embedding [C]//Proceeding of the IEEE International Conference on Com-

puter Vision (ICCV). 2005; 1208-1213
 [6] Li H F, Jiang T, Zhang K S. Efficient and robust feature extraction by maximum margin criterion [J]. IEEE Transactions on Neural Networks, 2006, 17(1): 157-165
 [7] Yan S C, Xu D, Zhang B Y, 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
 [8] 林玉娥, 李敬兆, 梁兴柱, 等. 边界近邻零空间鉴别分析[J]. 计算机科学, 2013, 40(3): 291-294
 [9] Cheng H, Liu Z, Yang L, et al. Sparse representation and learning in visual recognition: theory and applications [J]. Signal Processing, 2013, 93(6): 1408-1425
 [10] Wright J, Ma Y, Mairal J, et al. Sparse representation for computer vision and pattern recognition [J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044
 [11] 殷飞, 焦李成. 基于旋转扩展和稀疏表示的鲁棒遥感图像目标识别[J]. 模式识别与人工智能, 2012, 25(1): 89-95
 [12] Qiao L, Chen S, Tan X. Sparsity preserving projections with applications to face recognition [J]. Pattern Recognition, 2010, 43(1): 331-341
 [13] Zang F, Zhang J. Discriminative learning by sparse representation for classification [J]. Neurocomputing, 2011, 74(12/13): 2176-2183
 [14] Yin F, Jiao L C, Shang F, et al. Fast fisher sparsity preserving projections [J]. Neural Computing and Applications, 2013, 23(3/4): 691-705
 [15] Turk M A, Pentland A P. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86
 [16] 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
 [17] 高翠珍, 胡建龙, 李德玉. 保持局部邻域关系的增量 Hessian LLE 算法[J]. 计算机科学, 2012, 39(4): 217-219
 [18] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 19(7): 1373-1396
 [19] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(5500): 2323-2326
 [20] Tao Y, Yang J. Quotient vs. difference: comparison between the two discriminant criteria [J]. Neurocomputing, 2010, 73(10-12): 1808-1817
 [21] Wang H, Yan S, Xu D, et al. Trace ratio vs. ratio trace for dimensionality reduction [C]// Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2007: 1-8
 [22] Olivetti Oracle Research Lab (ORL) Database [EB/OL]. <http://www.cl.cam.ac.uk/research/dt-g/attarchive/facedatabase.html>
 [23] He X, Yan S, Hu Y, et al. Face recognition using laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340