

7-3-2020

## Face Recognition Method Based on Cost-Sensitive Supervised Manifold Learning

Yeqin Cui

*College of Mathematics and Information Science, Langfang Normal University, Langfang 065000, China;*

Jianguo Gao

*College of Mathematics and Information Science, Langfang Normal University, Langfang 065000, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Face Recognition Method Based on Cost-Sensitive Supervised Manifold Learning

## Abstract

**Abstract:** Existing subspace learning-based face recognition methods assume the same loss from all misclassifications. In the real-world face recognition applications, however, different misclassifications can lead to different losses. Motivated by this concern, *a cost-sensitive supervised manifold learning approach for face recognition was proposed. The proposed approach incorporated a cost matrix to specify the different costs associated with misclassifications of subjects, into locality preserving projection algorithm, which devised the corresponding cost-sensitive methods, namely, cost-sensitive locality preserving projections (Cos-Sen LPP), to achieve a minimal overall loss.* Three face databases were put into the experiments and experimental results show that Cos-Sen LPP method can achieve minimal cost than existing subspace learning-based face recognition methods.

## Keywords

cost-sensitive, manifold learning, face recognition, Locality Preserving Projections (LPP)

## Recommended Citation

Cui Yeqin, Gao Jianguo. Face Recognition Method Based on Cost-Sensitive Supervised Manifold Learning[J]. Journal of System Simulation, 2016, 28(5): 1077-1085.

# 代价敏感的监督流形学习人脸识别方法

崔业勤, 高建国

(廊坊师范学院数学与信息科学学院, 河北 廊坊 065000)

**摘要:** 基于子空间学习的人脸识别均假设所有错误识别会导致一样的损失。在人脸识别应用中, 不同的错误识别造成的损失则不同。提出一种代价敏感的监督流形学习人脸识别方法, 该方法采用一个代价矩阵来指定不同的误分类代价, 并将其容纳到局部保持投影(Locality Preserving Projections, LPP)算法中, 获得相应的代价敏感局部保持投影(Cos-Sen LPP), 以实现人脸识别整体损失最小化。在 3 个人脸数据库上的实验结果表明, 与现有的子空间学习方法相比, Cos-Sen LPP 方法花费了最少的整体代价。

**关键词:** 代价敏感; 流形学习; 人脸识别; 局部保持投影

中图分类号: TP391 文献标识码: A 文章编号: 1004-731X (2016) 05-1077-09

## Face Recognition Method Based on Cost-Sensitive Supervised Manifold Learning

Cui Yeqin, Gao Jianguo

(College of Mathematics and Information Science, Langfang Normal University, Langfang 065000, China)

**Abstract:** Existing subspace learning-based face recognition methods assume the same loss from all misclassifications. In the real-world face recognition applications, however, different misclassifications can lead to different losses. Motivated by this concern, a cost-sensitive supervised manifold learning approach for face recognition was proposed. The proposed approach incorporated a cost matrix to specify the different costs associated with misclassifications of subjects, into locality preserving projection algorithm, which devised the corresponding cost-sensitive methods, namely, cost-sensitive locality preserving projections (Cos-Sen LPP), to achieve a minimal overall loss. Three face databases were put into the experiments and experimental results show that Cos-Sen LPP method can achieve minimal cost than existing subspace learning-based face recognition methods.

**Keywords:** cost-sensitive; manifold learning; face recognition; Locality Preserving Projections (LPP)

## 引言

子空间学习技术已被广泛应用于人脸识别<sup>[1-7]</sup>, 并且很多子空间学习算法在近几年被提出<sup>[5-17]</sup>。子空间学习人脸识别其目标是在有监督或无监督情况下, 学习人脸特征的低维特征空间表示, 保留

原始人脸图像的固有特征。主成分分析<sup>[14]</sup>(Principal Component Analysis, PCA)和线性判别分析<sup>[15]</sup>(Linear Discriminant Analysis, LDA)是 2 个有代表性的子空间学习方法。PCA 通过映射原始高维人脸图像至低维线性子空间来实现特征提取, 此子空间由协方差矩阵若干个相互正交的特征向量组成, 并保留人脸图像的最大方差。LDA 目标是寻找最优的判别投影, 使得类间方差与类内方差的比例最大化。LDA 往往优于 PCA 识别, 因为 LDA 考虑了类的信息。尽管这 2 种算法在人脸识别中得到了



收稿日期: 2014-09-25 修回日期: 2015-05-08;  
作者简介: 崔业勤(1973-), 女, 河北廊坊, 硕士, 副教授, 研究方向为计算机视觉、模式识别与人工智能; 高建国(1970-), 男, 河北廊坊, 硕士, 副教授, 研究方向为数据库、图形图像处理与机器学习理论。

<http://www.china-simulation.com>

• 1077 •

较好的应用,但在探索高维人脸样本的非线性流形时效果不佳。

近年来,很多基于流形学习算法的人脸识别方法被提出<sup>[1-7,15,18]</sup>。这些方法的基本思路是:高维人脸图像能被看作是一系列几何相关的点或落在光滑低维流形上<sup>[16-17]</sup>,最具代表性的算法之一是局部保持投影<sup>[19]</sup>(Locality Preserving Projections, LPP),其目标是寻找一个低维子空间以保留原始样本的内在几何结构,保持投影在同一个邻域内样本的局部关系。LPP 起初为无监督算法,而最近的很多工作都考虑了类的信息,从而衍生出许多判别流形学习算法,如邻域保持判别投影<sup>[6]</sup>(Neighborhood Preserving Discriminant Projections, NPDP)、局部判别嵌入<sup>[8]</sup>(Local Discriminant Embedding, LDE)、边界 Fisher 分析<sup>[18,20]</sup>(Margin Fisher Analysis, MFA)、判别局部保持投影<sup>[21]</sup>(Discriminant Locality Preserving Projections, DLPP)以及有监督的 LPP 算法<sup>[22]</sup>等,均提升了识别性能。尽管这些方法有不同的假设条件,但它们可以统一成广义的具有不同限制的图嵌入(Graph Embedding, GE)框架<sup>[2,12,18]</sup>。目前,一些新的非线性降维算法被提出,已经成功应用到人脸识别等领域<sup>[23-24]</sup>。

然而,现有的基于子空间学习的人脸识别方法均以低识别错误率为目标,并假设所有的错误识别会导致一样的损失。然而,此假设可能不适合现实世界人脸识别的应用。例如,金库准入者被误识而不能进入房间,这可能仅会造成不便;但金库非准入者被误识而进入房间,这会造成非常严重的损失。因此,在现实世界的人脸识别系统中,不同的识别错误可能会造成不同的损失。目前,明确考虑此现象的人脸识别算法很少。据了解,文献[25]是首次工作,它通过形式化多级代价敏感分类问题来解决在人脸识别系统所造成的不同损失。尽管此方法提高了识别性能(较小的识别损失),但它仅仅在分类阶段使用了代价敏感学习技术,而没有在特征提取(子空间学习)阶段使用;换句话说,不同代价的样本并没有被利用在特征提取阶段,因此,有

用的代价敏感信息可能在此阶段被忽略,导致次优的解决方案。

基于此,提出一种新的基于代价敏感的子空间学习人脸识别方法,该方法采用一个代价矩阵来指定不同的误分类代价,并将此矩阵容纳到经典的基于流形学习的局部保持投影(LPP)算法中,获得相应的代价敏感局部保持投影(Cos-Sen LPP)方法,以实现人脸识别整体损失最小化。在 AR, FERET 和 UMIST 3 个人脸数据库上的实验结果证明,与现有的子空间学习方法相比, Cos-Sen LPP 方法花费了最少的整体代价,并达到了较低的错误识别率、错误拒绝率和错误接受率。

## 1 提出的方法

现有的子空间学习人脸识别方法,如 PCA, LPP, DLPP, LDE 等,均假设所有错误分类导致相同的损失。与这些方法不同,提出的 Cos-Sen LPP 方法明确将代价敏感信息纳入到人脸识别的特征提取(子空间学习)中。首先,回顾一下局部保持投影(LPP)方法。

### 1.1 局部保持投影(LPP)

局部保持投影(LPP)通过一定的性能目标来寻找线性变换  $W$ , 以实现对高维数据的降维:

$$y_i = W^T x_j, \quad j = 1, 2, \dots, l \quad (1)$$

已知存在  $l$  个训练样本  $X = \{x_i\}_{i=1}^l \in R^m$ , 变换矩阵  $W$  可以通过最小化如下目标函数来得到:

$$\min \left( \sum_{i,j} (W^T x_i - W^T x_j)^2 S_{ij} \right) \quad (2)$$

其中:  $S$  是权值矩阵, 采用  $k$  近邻法定义:

$$S_{ij} = \begin{cases} e^{-\|x_i - x_j\|^2 / t}, & x_j \text{ 是 } x_i \text{ 的 } k \text{ 个近邻点} \\ 0, & \text{其它} \end{cases} \quad (3)$$

其中:  $t$  是一个大于 0 的常量。

从目标函数(2)可看出, 降维后的特征空间能够保持原始高维空间的局部结构。对式(2)进行代数变换:

$$\frac{1}{2} \sum_{i,j} (\mathbf{W}^T x_i - \mathbf{W}^T x_j)^2 S_{ij} =$$

$$\sum_{i,j} \mathbf{W}^T x_i \mathbf{D}_{ii} x_i^T \mathbf{W} - \sum_{i,j} \mathbf{W}^T x_i S_{ij} x_j^T \mathbf{W} =$$

$$\mathbf{W}^T \mathbf{X} (\mathbf{D} - \mathbf{S}) \mathbf{X}^T \mathbf{W} = \mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} \quad (4)$$

其中:  $\mathbf{X} = [x_1, x_2, \dots, x_l]$ ,  $\mathbf{D}$  是  $l \times l$  对角阵, 对角元素  $D_{ii} = \sum_j S_{ij}$ ,  $\mathbf{L} = \mathbf{D} - \mathbf{S}$ 。

能够使式(4)取最小值的变换矩阵  $\mathbf{W}$  可以通过求解如下广义本征值问题而得到:

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{W} \quad (5)$$

这样, 式(5)的  $d$  个最小的非零特征值所对应的特征向量构成投影矩阵  $\mathbf{W} = [w_1, w_2, \dots, w_d]$ 。

## 1.2 代价敏感的局部保持投影

### 1.2.1 问题的提出

在一个实际的人脸识别系统中, 识别一个测试人脸样本的错误类型通常有 3 种:

- 1) 错误拒绝: 将金库准入者误认为是金库非准入者(冒名顶替者);
- 2) 错误接受: 将金库非准入者(冒名顶替者)误认为是金库准入者;
- 3) 错误鉴定: 将金库准入者误认为是另一个金库准入者。

对于一个现实的应用而言, 因错误接受导致的损失可能远比错误拒绝造成的损失大得多。此外, 金库准入者被误认为是另一个金库准入者或金库非准入者很可能导致不同的损失。鉴于此情况, 提出将由不同分类错误造成的不同损失纳入到人脸识别系统的特征提取(子空间学习)阶段。为方便讨论, 假设接受任何冒名顶替者造成的损失相同; 而当一个金库准入者被误认为是另一个金库准入者或冒名顶替者时, 造成的损失不同。在没有任何先验信息的情况下, 此种假设对大多数实际人脸识别系统是合理的。

令  $\mathbf{X} = [x_1, x_2, \dots, x_{N_1+1}, \dots, x_{N_1+N_2}]$  为一人脸图像集, 其中,  $x_i \in R^d, 1 \leq i \leq N_1 + N_2$ ,  $N_1$  和  $N_2$  分

别是金库准入者和冒名顶替者的图像集中成员,  $d$  是每张人脸样本的特征维度。令  $x_i$  类标签为  $l_i \in \{G_1, G_2, \dots, G_c, I\}$ ;  $G_j (j=1, 2, \dots, c)$  和  $I$  分别是金库准入人和冒名顶替者的集合;  $C_{GI}$ ,  $C_{IG}$  和  $C_{GG}$  分别是由错误拒绝、错误接受和错误识别所产生的代价。不失一般性, 在不影响最终结果的情况下, 假设  $C_{GI} = C_{GI}/C_{GG}$ ,  $C_{IG} = C_{IG}/C_{GG}$  和  $C_{GG} = 1$ ; 然后, 构建如表 1 所示的代价矩阵,  $C_{ij}$  指第  $i$  类人脸图像被错误识别为第  $j$  类的代价。对于正确的识别将不会产生损失, 因此, 代价矩阵的对角线元素均为零。这里必须指出的是: 代价矩阵可以根据不同的应用需求而有不同的设置。

表 1 人脸识别系统的代价矩阵  $\mathbf{C}$

代价	$G_1$	...	$G_c$	$I$
$G_1$	0	...	$C_{GG}$	$C_{GI}$
...	...	...	...	...
$G_c$	$C_{GG}$	...	0	$C_{GI}$
$I$	$C_{IG}$	...	$C_{IG}$	0

### 1.2.2 Cos-Sen LPP 实现

将代价矩阵纳入子空间学习方法 LPP 中, 获得相应的 Cos-Sen LPP 方法。令  $N = N_1 + N_2$ , 并重新划定  $\mathbf{X} = [x_1, x_2, \dots, x_N]$ 。  $\overline{\mathbf{W}} = [\overline{w}_1, \overline{w}_2, \dots, \overline{w}_k]$  为要寻找的代价敏感子空间, 即  $\overline{\mathbf{W}}$  将  $x_i$  映射为一个低维特征  $y_i = \overline{\mathbf{W}}^T x_i, y_i \in R^k, k \leq d$ 。事实上, 不同代价敏感子空间学习方法之间的本质区别在于它们定义和寻找投影矩阵  $\overline{\mathbf{W}}$  有所不同。

综上, 将 Cos-Sen LPP 的目标定义如下:

$$\min \sum_{i=1}^N \sum_{j=1}^N \text{cost}(y_i, y_j) (y_i - y_j)^2 S_{ij} \quad (6)$$

其中:  $\text{cost}(y_i, y_j)$  表示将  $y_i$  误认为是  $y_j$  的代价,  $S_{ij}$  定义与 LPP 定义相同。让  $x_i$  和  $x_j$  分别属于训练集中第  $t_1$  和第  $t_2$  类,  $1 \leq t_1, t_2 \leq c+1$ , 则有  $\text{cost}(y_i, y_j) = \text{cost}(x_i, x_j) = C_{t_1, t_2}$ , 此代价可从代价矩阵  $\mathbf{C}$  中获得<sup>[25]</sup>。经代数运算, 可将目标函数简化为以下形式:

$$\begin{aligned} & \sum_{i=1}^N \sum_{j=1}^N \text{cost}(y_i, y_j) (\omega^T x_i - \omega^T x_j)^2 S_{ij} = \\ & \sum_{i=1}^N \sum_{j=1}^N \text{cost}(x_i, x_j) \omega^T (x_i - x_j) (x_i - x_j)^T \omega S_{ij} = \\ & 2 \sum_{i=1}^N \text{cost}(x_i, x_j) \omega^T x_i S_{ii} x_i \omega - \\ & 2 \sum_{i=1}^N \sum_{j=1, j>i}^N \text{cost}(x_i, x_j) \omega^T x_i S_{ij} x_j \omega = \\ & -2 \omega^T A \omega \end{aligned} \quad (7)$$

其中,  $A = \sum_{i=1}^N \sum_{j=1, j>i}^N \text{cost}(x_i, x_j) x_i S_{ij} x_j^T$ 。为了解决该

最小化问题, 对其施加正交约束  $\omega^T \omega = 1$ ; 形式化 Cos-Sen LPP 为如下约束优化问题:

$$\begin{cases} \max_{\omega} & \omega^T A \omega \\ \text{s.t.} & \omega^T \omega = 1 \end{cases} \quad (8)$$

通过解决如下特征方程得到式(8)的最优解:

$$A \omega = \lambda \omega \quad (9)$$

$[\omega_1, \omega_2, \dots, \omega_k]$  是前  $k$  个最大特征值 ( $\{\lambda_i | i=1, 2, \dots, k\}$ ,  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$ ) 对应的特征向量, 即  $\bar{W} = [\omega_1, \omega_2, \dots, \omega_k]$  为 Cos-Sen LPP 的子空间投影。

综上所述, 采用 Cos-Sen LPP 算法进行人脸识别的基本步骤如下:

- 1) 根据现实应用需求定义代价矩阵  $C$ ;
- 2) 从代价矩阵  $C$  中获得  $\text{cost}(x_i, x_j)$ ;
- 3) 求解 Cos-Sen LPP 目标函数(6), 即求解特征方程(9), 即获得前  $k$  个最大特征值对应的特征向量  $\bar{W} = [\omega_1, \omega_2, \dots, \omega_k]$ ;
- 4) 根据最近邻分类器在欧氏空间内进行识别。

### 1.2.3 讨论分析

在本小节中, 讨论提出的 Cos-Sen LPP 方法与 2 类相关工作之间的关系: 1) 现有的子空间学习方法<sup>[5,15,18]</sup>; 2) 代价敏感分类器<sup>[25]</sup>。

与 1) 的关系: 现有的子空间学习人脸识别方法其目标是为了实现低识别错误率, 并假设所有错

误分类的损失是相同的。因此, 它们可被视为统一代价的方法; 相对地, Cos-Sen LPP 方法其目的是实现低损失, 而不是低识别错误率, 这将更适合现实世界中的人脸识别应用。

与 2) 的关系: 最近, Zhang 等人<sup>[25]</sup>提出了用于人脸识别 2 种代价敏感的分类方法, 称为多类代价敏感核 logistic 回归(mcMLR)和多类代价敏感的  $k$ -近邻(mckNN)。尽管识别性能(较小的识别损失)得到提高, 但它们仅仅在分类阶段使用了代价敏感学习技术, 而没有在特征提取(子空间学习)阶段使用。换句话说, 不同代价的样本并没有被利用在特征提取阶段, 因此, 有用的代价敏感信息可能在此阶段被忽略, 导致次优的解决方案。而提出的方法明确指出, 不同类别的样本代价敏感信息利用在训练阶段, 而不是在分类阶段。此外, 实验结果也表明, 当提出的 Cos-Sen LPP 方法用于识别时, 其性能也会得到进一步提升。具体细节见下一节。

## 2 实验结果与分析

实验在 Windows XP 操作系统、Intel Core(TM) 2.8 GHz CPU 以及 3.5G SDRAM 内存的 PC 机器上执行, 算法在 MATLAB 7.10.0 平台下实现, 如图 1 为软件操作界面及代码界面。

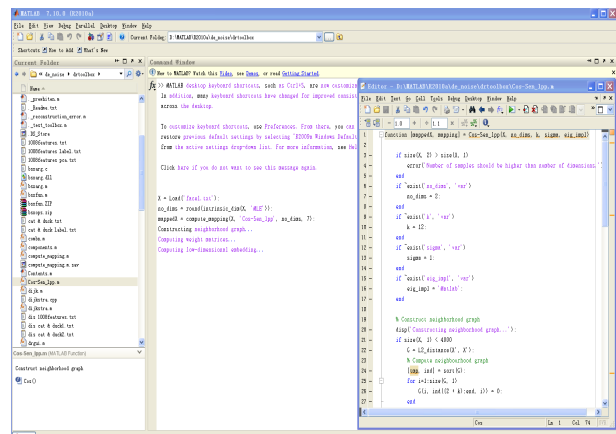


图 1 软件操作界面

在实验中, 采用 AR<sup>[26]</sup>, FERET<sup>[27]</sup>和 UMIST<sup>[28]</sup>



人脸数据库评价提出方法的有效性。AR 数据库包含 126 名对象(70 名男性和 56 名女性), 超过 4 000 张人脸图像, 包括不同照明条件下的面部表情。选择 110 名对象的 1 540 张人脸图像作为一个子集, 每名测试者有 14 张在不同照明条件下的人脸图像; 对于 FERET 数据库, 包含 1 199 名对象, 共有超过 14 000 张人脸图像, 这些图像包含不同的灯光变化、姿态等面部表情; 对于 UMIST 数据库, 包含 20 名对象, 共有 564 张人脸图像, 包含不同的种族、性别和表情, 以及从侧面到正面不同角度的拍照。图 2 为 3 个人脸数据库的部分人脸实例。所有人脸图片被截成  $32 \times 32$  像素图片, 根据眼睛的位置对齐排列。对于每个数据库, 令训练集和测试集均包含  $M$  个合法准入者的  $N_G$  个图像, 并且从整个数据库中随机选择  $N_I$  个冒名顶替者的图像。每个数据库重复此选择 10 次, 并以平均识别精度作为最终的识别结果。表 2 为参数的具体设置。

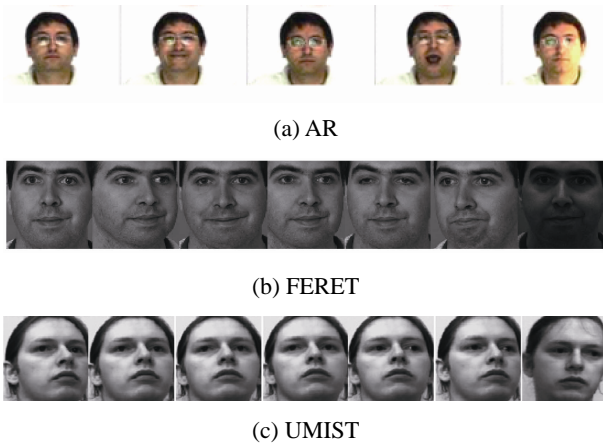


图 2 人脸实例

表 2 实验设置

数据库	$M$	$N_G$	$N_I$	$C_{IG}: C_{GI}: C_{GG}$
AR	35	8	300	20:2:1
FERET	80	4	300	20:2:1
UMIST	8	3	100	10:2:1

下面, 在 AR, FERET 和 UMIST 3 个数据库上进行人脸识别实验。将提出的 Cos-Sen LPP 方法与经典的子空间学习方法 LDE<sup>[8]</sup>, LLE<sup>[16]</sup>, LPP<sup>[19]</sup> 进行比较。首先, 对基于子空间学习方法的维度选

取进行说明。使用 Levina 等人提出的最大似然评估(MLE)方法<sup>[29]</sup>来估计原始高维数据的固有维度, 即降至的维度  $d$ 。MLE 方法的基本思想为: 固定一样本点  $x$ , 假设在以  $x$  为中心,  $R$  为半径的小球  $S_x(R)$  中有  $f(x) \approx const$ , 且在  $S_x(R)$  中的样本点服从均匀的 Poisson 分布, 则可通过公式(10)先进行局部评估:

$$d_k(x_i) = \frac{\sum_{j=1}^{k-1} \log(T_k(x_i)/T_j(x_i))}{k-1} \quad (10)$$

其中:  $T_k(x_i)$  指  $x_i$  与其第  $k$  个最近邻点的距离。这样, 原始高维数据的固有维度被评估为:

$$d = \frac{\sum_{i=1}^N d_k(x_i)}{N} \quad (11)$$

通过 MLE 方法对 3 组人脸数据进行固有维度评估, 得到 AR, FERET 和 UMIST 的固有维度分别为: 23.47, 11.76 和 6.24, 即取整为 23, 12 和 6。此外, 由经验参数得到: 对于 AR 数据库, 其子空间学习算法的近邻个数选取为 8; 对于 FERET 和 UMIST 数据库, 其子空间学习算法的近邻个数选取为 12。所有方法采用最近邻(MN)规则, 在欧氏空间内进行识别, 对不同方法的总代价(cost)进行了评价, 同时也评价了人脸识别中常用的指标: 总错误率(Total Error Rate, TER)、错误拒绝率(False Rejection Rate, FRR)和错误接受率(False Acceptance Rate, FAR)。说明:  $cost = \sum_{i=1}^N \sum_{j=1}^N cost(y_i, y_j)$ ; FRR 指将金库准入者误认为金库非准入者数与总研究人数的比值; FAR 指将金库非准入者误认为金库准入者数与总研究人数的比值; TER 指错误匹配的次数/比对总数。


为公平起见, 比较的所有方法均为最优参数下获得结果, 如表 3 所示, 提出的 Cos-Sen LPP 方法比现有的统一代价的子空间学习方法具有较小的总代价。此外, 提出的代价敏感变化的总误差率也明显低于现有的方法, 其原因是: 尽管传统的统一代价子空间学习算法是为了达到较低的错误识别率, 但是它们没有考虑训练样本的不同重要性, 尤其是那些冒名顶替类, 这些样本更容易被误判。

表 3 3 个数据库上总代价(cost)、总错误率(TER)、  
错误拒绝率(FRR)和错误接受率(FAR)的比较

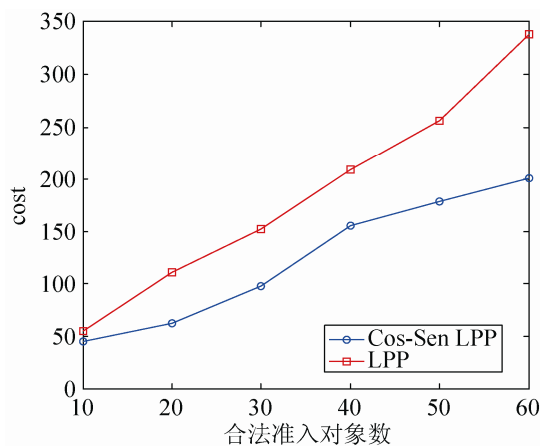
		方法			
数据库		LDE	LLE	LPP	Cos-Sen LPP
AR	cost	889	924	869	583
	TER %	22.48	23.54	21.36	15.17
	FRR %	35.08	40.23	38.62	20.45
	FAR %	10.62	13.59	10.91	8.53
FERET	cost	315	352	338	201
	TER %	9.57	10.34	10.42	6.03
	FRR %	22.57	23.68	21.49	12.45
	FAR %	2.98	4.62	3.78	2.36
UMIST	cost	98	106	92	46
	TER %	8.32	9.56	8.64	7.52
	FRR %	18.39	21.22	19.86	14.23
	FAR %	6.17	7.68	5.86	3.64

此外,对 LPP 和对应的 Cos-Sen LPP 在不同合法准入者数  $M$  下的总代价进行了评价。对于 AR 和 FERET 数据库,  $M$  子集从 10~60, 以 10 为增量变化。对于 UMIST 数据库,  $M$  子集从 4~14, 以 2 为增量变化。图 3 显示了 2 种方法的总代价, 可以清楚看到, 在不同数目的合法准入者实验中, 提出的 Cos-Sen LPP 方法的总代价比 LPP 方法要低。


进一步,在 3 个数据库上比较了提出的 Cos-Sen LPP 方法在不同分类器下的性能。根据表 1 设置的参数值, 选择最新的代价敏感分类器—mc  $k$  NN 分类器<sup>[25]</sup>, 与传统的统一代价的  $k$  NN 分类器进行性能对比。在实验中, 设置  $k=1$ , 这样, 传统的  $k$  NN 分类器即为著名的 NN 分类器。表 4 呈现了 2 个不同分类器分别应用在 3 个数据库的 Cos-Sen LPP 总代价, 可以看到, 当使用代价敏感分类器时, 总代价得到进一步降低。图 4 是基于 Cos-Sen LPP 的代价敏感 mc  $k$  NN 分类器在不同 cost 设置下 FAR 和 FRR 的结果, 体现了二者之间的关系。图 5 是  $k$  NN 与 mc  $k$  NN 分类器在不同  $k$  下的实验结果, 表明了 mc  $k$  NN 分类器具有较好的优势。表 5 和表 6 分别为不同  $C_{IG}/C_{GI}$  值和不同  $C_{GI}/C_{GG}$  值下, 基于 LPP 和 Cos-Sen LPP 的 2 种分类器在不同指标衡量下的总代价, 可以看到, 在不同  $C_{IG}/C_{GI}$  值和不同  $C_{GI}/C_{GG}$  值下, Cos-Sen LPP 的总代价总是最低的。



(a) AR 数据库



(b) FERET 数据库



(c) UMIST 数据库

图 3 不同数目金库准入者总代价比较结果

表 4 使用代价统一和代价敏感 NN 分类器的子空间学习总代价比较

数据库 方法	AR	FERET	UMIST
统一代价 $k$ NN	581	236	63
代价敏感 mc $k$ NN	523	182	42



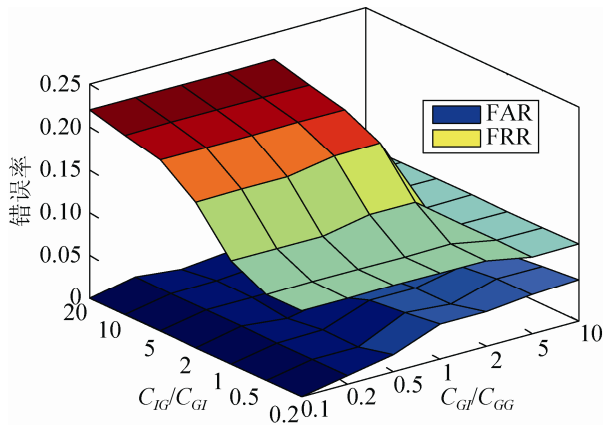


图 4 基于 Cos-Sen LPP 的代价敏感 mc k NN 分类器在不同 cost 设置下的结果

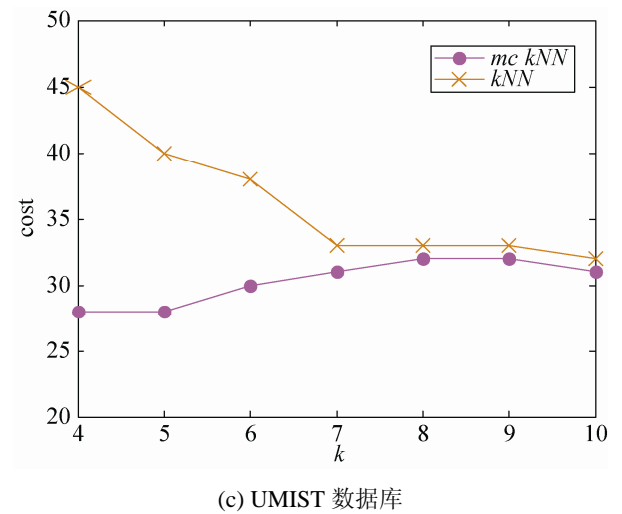
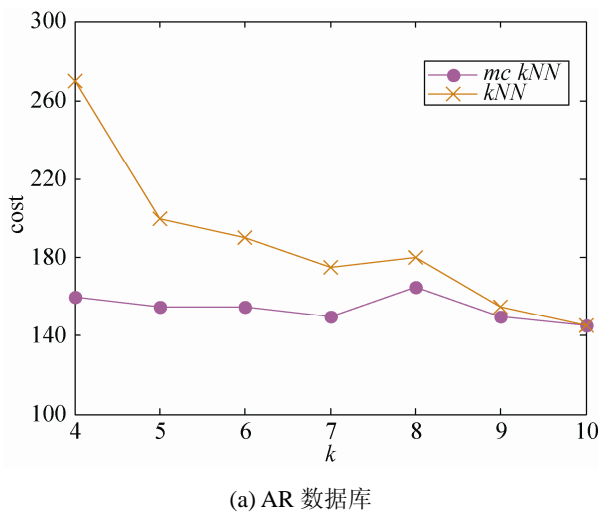
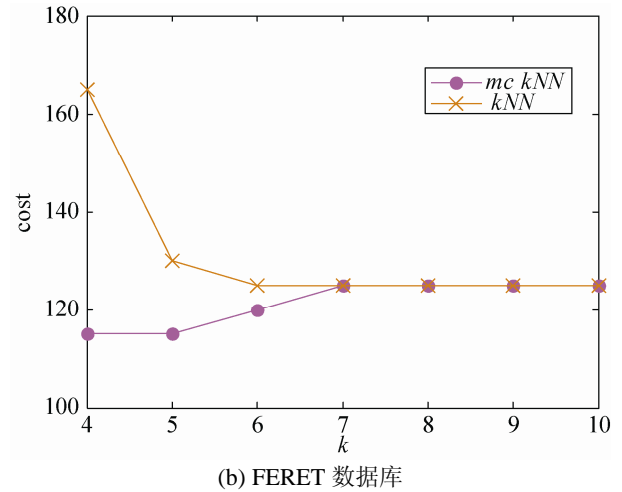


图 5 k NN 与 mc k NN 分类器在不同 k 下的实验结果

表 5 基于 LPP 的 2 种分类器在不同指标衡量下的代价

数据库	分类器指标	AR		FERET		UMIST			
		k NN	mc k NN	K NN	mc k NN	k NN	mc k NN		
$C_{IG}/C_{GI}$	0.2	182	102	175	98	69	36		
	1	209	126	196	105	81	42		
	5	368	162	204	116	89	48		
	20	392	187	211	116	93	53		
$C_{GI}/C_{GG}$	0.2	89	21	93	26	76	19		
	1	143	49	187	62	104	46		
	5	562	413	364	283	153	103		
	10	982	836	653	576	396	314		
测试对象数	10	235	173	20	165	122	10	97	54
	15	296	258	40	278	236	15	175	126
	20	384	312	60	387	342	20	304	248
	25	435	395	80	533	480	25	387	324

表 6 基于 Cos-Sen LPP 的 2 种分类器在不同指标衡量下的代价

数据库	分类器指标	AR		FERET		UMIST			
		$k$ NN	mc $k$ NN	$k$ NN	mc $k$ NN	$k$ NN	mc $k$ NN		
$C_{IG}/C_{GI}$	0.2	154	85	146	71	51	26		
	1	163	104	158	91	46	35		
	5	321	122	185	98	69	41		
	20	364	156	186	98	78	44		
$C_{GI}/C_{GG}$	0.2	64	16	75	19	54	15		
	1	115	32	155	46	85	37		
	5	504	52	307	241	116	84		
	10	891	759	598	511	326	271		
测试对象数	10	202	146	20	126	95	10	72	39
	15	258	207	40	225	196	15	138	94
	20	365	275	60	354	307	20	271	215
	25	394	348	80	486	423	25	367	291

### 3 结论

提出了一种用于人脸识别的代价敏感子空间学习方法。在现实世界中的人脸识别系统中,由于不同类型的错误分类通常会导致不同的代价,提出一种代价敏感的子空间学习方法,即代价敏感的局部保持投影(Cos-Sen LPP)。当在低维子空间中进行识别时,可以实现较低的识别损失,而不是较低的识别错误率。实验结果也证明了该方法的有效性。该研究对处理现实场景中的人脸数据具有重大意义。

### 参考文献:

- [1] Lu J, Tan Y P. Uncorrelated Discriminant Nearest Feature Line Analysis for Face Recognition [J]. IEEE Signal Processing Letters(S1558-2361), 2010, 17(2): 185-188.
- [2] Cai D, He X, Hu Y, et al. Learning a Spatially Smooth Subspace for Face Recognition [C]// Proceedings of IEEE International Conference on Computer Vision and Pattern Recognition, 2007. USA: IEEE, 2007: 1-7.
- [3] Chen D Y, Chen X H. Face Recognition Based on Orthogonal and Uncorrelated Marginal Neighborhood Preserving Embedding [J]. Journal of Computer Applications (S0974-1925), 2013, 33(11): 3097-3101.
- [4] Zhang Z W, Yang F, Xia K W, et al. A Supervised LPP Algorithm and Its Application to Face Recognition [J]. Journal of Electronics & Information Technology (S1009-5896), 2008, 30(3): 539-541.
- [5] He X, Yan S, Hu Y, et al. Face Recognition Using Laplacian Faces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2005, 27(3): 328-340.
- [6] Hu H. Orthogonal Neighborhood Preserving Discriminant Analysis for Face Recognition [J]. Pattern Recognition (S0031-3203), 2008, 41(6): 2045-2054.
- [7] Lu J, Tan Y P. Regularized Locality Preserving Projections and Its Extensions for Face Recognition [J]. IEEE Transactions on Systems, Man, and Cybernetics: Part B, Cybernetics (S1083-4419), 2010, 40(3): 958-963.
- [8] Chen H, Chang H, Liu T. Local Discriminant Embedding and Its Variants [C]// Proceedings of IEEE International Conference on Computer Vision and Pattern recognition, 2005. USA: IEEE, 2005: 846-853.
- [9] Gao X F, Liang J Y. Manifold Learning Algorithm DC-ISOMAP of Data Lying on the Well-separated Multi-manifold with Same Intrinsic Dimension [J]. Journal of Computer Research and Development (S1000-1239), 2013, 50(8): 1690-1699.
- [10] He G H, Zhang T P, Tang Y Y. Correlation-based Multidimensional Scaling for Unsupervised Subspace Learning [J]. Journal of Image and Graphics (S0219-4678), 2011, 16(12): 2152-2158.
- [11] Zheng J W, Qiu H, Jiang Y B, et al. Discriminative Stochastic Neighbor Embedding Analysis Method [J]. Journal of Computer-Aided Design & Computer Graphics(S1003-9775), 2012, 24(11): 1477-1484.
- [12] Cai D, He X, Han J. Spectral Regression for Efficient Regularized Subspace Learning [C]// Proceedings of

- IEEE International Conference on Computer Vision. USA: IEEE, 2007: 1-8.
- [13] Lu J, Tan Y P. A Doubly Weighted Approach for Appearance Based Subspace Learning Methods [J]. IEEE Transactions on Information Forensics and Security (S1556-6013), 2010, 5(1): 71-81.
- [14] Turk M, Pentland A. Eigenfaces for Recognition [J]. Journal of Cognitive Neuroscience(S0898-929X), 1991, 3(1): 71-86.
- [15] Belhumeur P N, Hespanha J, Kriegman D J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 1997, 19(7): 711-720.
- [16] Roweis S, Saul L. Nonlinear Dimensionality Reduction by Locally Linear Embedding [J]. Science (S0036-8075), 2000, 290(5500): 2323-2326.
- [17] Tenenbaum J B, Silva V, Langford J. A Global Geometric Framework for Nonlinear Dimensionality Reduction [J]. Science (S0036-8075), 2000, 290(5500): 2319-2323.
- [18] Yan S, 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 (S0162-8828), 2007, 29(1): 40-51.
- [19] He X, Niyogi P. Locality Preserving Projections [C]// Advances in Neural Information Processing Systems 16, Vancouver, British Columbia, Canada. MIT Press, 2003: 153-160.
- [20] 何进荣, 丁立新, 崔梦天, 等. 基于矩阵指数变换的边界Fisher分析[J]. 计算机学报, 2014, 37(10): 2196-2205.
- [21] Yu W, Teng X, Liu C. Face Recognition Using Discriminant Locality Preserving Projections [J]. Image and Vision Computing (S0262-8856), 2006, 24(3): 239-248.
- [22] 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, 30(3): 539-541.
- [23] 苏煜, 山世光, 陈熙霖, 等. 基于全局和局部特征集成的人脸识别 [J]. 软件学报, 2010, 8(2): 1849-1852.
- [24] 孙恒义, 樊养余, 温金环, 等. 基于度量优化的保持邻域嵌入的人脸识别 [J]. 计算机工程, 2011, 37(4): 195-198.
- [25] Zhang Y, Zhou Z H. Cost-sensitive Face Recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2010, 32(10): 1-8.
- [26] Martinez A M, Benavente R. The AR Face Database [R]// CVC Technical Report, #24, June, 1998.
- [27] Phillips P, Wechsler H, Huang J, et al. The FERET Database and Evaluation Procedure for Face-recognition Algorithms [J]. Image and Vision Computing (S0262-8856), 1998, 16(5): 295-306.
- [28] Graham D B, Allinson N M. Characterizing Virtual Eigen-signatures for General Purpose Face Recognition [J]. Computer and Systems Sciences (S1064-2307), 1998, 163(6): 446-456.
- [29] Levina E, Bickel P J. Maximum Likelihood Estimation of Intrinsic Dimension [C]// Advances in Neural Information Processing Systems. USA: MIT Press, 2005, 17: 777-784.