

一种面向人脸识别的加权代价敏感局部保持投影^{*}

万建武^{1,2}, 杨明^{1,2}, 吉根林², 陈银娟²

¹(南京师范大学 数学科学学院, 江苏 南京 210023)

²(南京师范大学 计算机科学与技术学院, 江苏 南京 210023)

通讯作者: 杨明, E-mail: myang@njnu.edu.cn, http://www.njnu.edu.cn

摘要: 传统的局部保持降维方法追求最低的识别错误率,即假设每一类的错分代价都是相同的.这个假设在真实的人脸识别应用中往往是不成立的.人脸识别是一个多类的代价敏感和类不平衡问题.例如,在人脸识别的门禁系统中,将入侵者错分成合法者的损失往往高于将合法者错分成入侵者的损失.因此,每一类的错分代价是不同的.另外,如果任一类合法者的样本数少于入侵者的样本数,该类合法者和入侵者就是类别不平衡的.为此,将错分代价融入局部保持的降维模型中,提出了一种错分代价最小化的局部保持降维方法.同时,采用加权策略平衡了各类样本对投影方向的贡献.在人脸数据集 AR, PIE, Extended Yale B 上的实验结果表明了该算法的有效性.

关键词: 局部保持降维;人脸识别;代价敏感学习;类不平衡;多类

中图法分类号: TP391 **文献标识码:** A

中文引用格式: 万建武,杨明,吉根林,陈银娟.一种面向人脸识别的加权代价敏感局部保持投影.软件学报,2013,24(5): 1155–1164. <http://www.jos.org.cn/1000-9825/4263.htm>

英文引用格式: Wan JW, Yang M, Ji GL, Chen YJ. Weighted cost sensitive locality preserving projection for face recognition. Ruan Jian Xue Bao/Journal of Software, 2013, 24(5): 1155–1164 (in Chinese). <http://www.jos.org.cn/1000-9825/4263.htm>

Weighted Cost Sensitive Locality Preserving Projection for Face Recognition

WAN Jian-Wu^{1,2}, YANG Ming^{1,2}, JI Gen-Lin², CHEN Yin-Juan²

¹(School of Mathematics Science, Nanjing Normal University, Nanjing 210023, China)

²(School of Computer Science and Technology, Nanjing Normal University, Nanjing 210023, China)

Corresponding author: YANG Ming, E-mail: myang@njnu.edu.cn, http://www.njnu.edu.cn

Abstract: Conventional locality preserving projection aims to minimize recognition error rate, implicitly assuming the losses of different misclassifications are the same. However, this may not hold in many real world face recognition applications. Face recognition is a multiclass cost sensitive and class imbalance task. For example, it will be troublesome if a gallery person is misclassified as an impostor, but it will be much more costly if an impostor is misclassified as a gallery person. Consequently, different kinds of mistakes will lead to different losses. Moreover, the examples of gallery person from any class are fewer than examples of the impostor, which is referred to as class imbalance. For that, this paper integrates the misclassification costs into an objective function of the locality preserving projection and proposes a cost sensitive locality preserving projection that minimizes the misclassification costs. Simultaneously, a weight strategy is used to balance the contribution of each class to the projection. Experimental results on AR, PIE, Extended Yale B datasets demonstrate the superiority of the proposed method.

Key words: locality preserving projection; face recognition; cost sensitive learning; class imbalance; multiclass

人脸识别^[1-10]是机器学习和模式识别领域的一个难点问题.目前,人脸识别有两种识别模式:verification 模

* 基金项目: 国家自然科学基金(60873176, 61272222, 61003116); 江苏省自然科学基金(BK2011782, BK2011005); 江苏省创新基金(CXZZ12_0386)

收稿时间: 2011-12-18; 修改时间: 2012-04-18; 定稿时间: 2012-05-18

式^[1-8]和 identification 模式^[9,10].本文主要关注 identification 模式. Identification 模式下的人脸识别问题是一个多类的代价敏感学习和类不平衡问题.例如,在人脸识别的门禁系统中,有入侵者和不同类别的合法者.将一个入侵者错分成合法者,并让其进入房间所带来的损失要远远大于将一个合法者拒之门外的损失;同时,将一个合法者拒之门外的损失又要大于将合法者识别为其他类别的合法者,而让其进入房间的损失.因此,不同的错分的损失不同,即每类样本的错分代价是不同的.另外,任一类合法者的样本数远少于入侵者的样本数,该类合法者和入侵者是类别不平衡的.

针对 identification 模式下的人脸识别问题,Zhou 等人提出了两种代价敏感的分类器^[9]:代价敏感的 logistic 回归和 k 近邻分类器.文献[9]考虑了类别间的错分代价,降低了分类的整体的错分代价,但它仅将错分代价融入到人脸识别的分类部分,而没有融入到降维部分.

人脸识别是一个高维数据识别问题.人脸识别系统通常采用先降维后分类的方式^[2,3,11-13].通过对人脸图像降维,我们可以解决维数灾难,提升算法的识别效率.目前,传统的降维方法只是追求最小的识别错误率,即假设每一类的错分代价都是相同的.这个假设在 identification 模式下是不成立的.针对该问题,Lu 等人提出了一种代价敏感的局部保持降维方法(cost sensitive locality preserving projection,简称 CSLPP)^[12].CSLPP 将错分代价融入到局部保持降维(locality preserving projection,简称 LPP)^[11]的模型中,但它:

- (1) 只能采用无监督的近邻图;
- (2) 最小化投影后异类样本间的距离,使原空间近邻的异类样本近邻得以保持,降低了投影方向 w 的判别能力;
- (3) 没有考虑人脸数据集中存在的类别不平衡问题,使得投影方向 w 由多数类决定,降低了 w 对少数类的局部保持能力.

为此,本文将错分代价融入到 LPP 的目标函数中,提出了一种错分代价最小化的局部保持降维方法.同时,采用了加权策略,平衡了不同类样本对投影方向的贡献.在人脸数据集 AR^[14],PIE^[3],Extended Yale B^[15]上的实验结果表明了算法的有效性.本文算法的主要贡献在于:

- (1) 对不同类样本分别设置不同的权重,平衡了各类样本对 LPP 投影方向 w 的贡献,提高了 LPP 投影方向对少数类的局部保持能力;
- (2) 将错分代价融入到 LPP 的降维模型中,使其满足错分代价最小化的准则,降低了分类的整体错分代价.

1 相关工作

1.1 局部保持降维

设 $X_{N \times D} = [x_1, x_2, \dots, x_N]^T$ 为给定的训练集, N, D 分别为样本数和维数. LPP^[11] 希望寻找投影方向 $w_{D \times d}, d \ll D$, 使得投影后的样本依然保持原空间样本间的近邻关系, 因此, LPP 的目标函数定义为

$$\min_w : \sum_{i=1}^N \sum_{j=1}^N \|w^T x_i - w^T x_j\|^2 S_{ij} \quad (1)$$

其中, S 是无监督的近邻图, 定义如下:

$$S_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / \delta^2), & \text{if } x_i \in knn(x_j) \text{ or } x_j \in knn(x_i) \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

其中, $knn(x_i)$ 表示训练集 X 中离样本 x_i 最近的 k 个样本集合.

如果训练集是监督的, 可以定义监督的近邻图 S :

$$S_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / \delta^2), & \text{if } l(x_i) = l(x_j) \text{ and } x_i \in knn(x_j) \text{ or } x_j \in knn(x_i) \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

其中, $l(x_i) = l(x_j)$ 表示样本 x_i 和 x_j 是同类样本.

监督的近邻图比无监督的近邻图更具有判别能力,有利于以分类为目的的机器学习问题.因此,基于判别近邻图的局部保持降维方法成为一个研究热点^[16-23].然而,在监督的近邻图下,LPP 的投影方向主要受多数类影响,少数类的局部保持能力得不到充分体现,其理论推导如下:假设样本集类别数为 C ,第 i 类的样本个数为 N_i , $N = \sum_{i=1}^C N_i$. 我们改写公式(1)得到:

$$\min_w: \sum_{p=1}^C \sum_{q=1}^C \sum_{i=1}^{N_p} \sum_{j=1}^{N_q} \|w^T x_i - w^T x_j\|^2 S_{ij} \quad (4)$$

根据公式(3)的定义,在近邻图 S 中,仅同类样本之间存在边,故公式(4)等价于:

$$\min_w: \left. \begin{aligned} &\sum_{p=1}^C \sum_{i=1}^{N_p} \sum_{j=1}^{N_p} \|w^T x_i - w^T x_j\|^2 S_{ij} = \text{tr} \left(w^T \sum_{p=1}^C A_p w \right) = \text{tr}(w^T A w) \\ &A = \sum_{p=1}^C A_p \\ &A_p = \sum_{i=1}^{N_p} \sum_{j=1}^{N_p} (x_i - x_j)(x_i - x_j)^T S_{ij} \end{aligned} \right\} \quad (5)$$

矩阵 A 是 LPP 模型的特征分解矩阵,对 A 进行特征分解就能求得 LPP 的投影向量 w .

矩阵 A 由每一类的协方差矩阵 $A_p(p=1, \dots, C)$ 组成,若第 p 类的样本数远多于其他任一类的样本数,则矩阵 A 主要由 A_p 决定,其他类的 $A_i(i=1, \dots, C, i \neq p)$ 在 A 中将得不到充分体现,影响投影方向 w 对少数类的局部保持能力.

1.2 代价敏感的局部保持降维

针对门禁系统问题^[9],Lu 等人提出了一种代价敏感的局部保持降维方法(CSLPP)^[12],其模型定义如下:

$$\min_w: \sum_{i=1}^N \sum_{j=1}^N Co(l(x_i), l(x_j)) \|w^T x_i - w^T x_j\|^2 S_{ij} \quad (6)$$

其中, S 是无监督的近邻图, Co 为错分代价矩阵.定义见表 1.在表 1 中, G 和 I 表示合法者和入侵者, $Co(G, I)$, $Co(I, G)$, $Co(G, G)$ 表示门禁系统的 3 种错分代价:(1) 将合法者错分成入侵者;(2) 将入侵者错分成合法者;(3) 将合法者错分成其他合法者.

Table 1 Cost matrix Co for face recognition

表 1 应用于人脸识别的代价矩阵 Co

	G_1	G_{C-1}	I
G_1	0	...	$Co(G, G)$
...	...	...	...
G_{C-1}	$Co(G, G)$	0	$Co(G, I)$
I	$Co(I, G)$	...	0

CSLPP 的近邻图 S 是无监督的,假设样本 x_i 的 k 个近邻中包含同类样本 x_p 和异类样本 x_q .根据代价矩阵 Co 的定义: $Co(l(x_i), l(x_p))=0$, $Co(l(x_i), l(x_q))>0$,可得:

$$\min_w: \sum_{i=1}^N \sum_{j=1, l(x_j) \neq l(x_i)}^N Co(l(x_i), l(x_j)) \|w^T x_i - w^T x_j\|^2 S_{ij} \quad (7)$$

公式(7)最小化了投影后异类样本间的距离,使得原空间近邻的异类样本近邻保持,降低了 w 的判别能力.

如果 CSLPP 采用监督的近邻图,观察公式(6)可知:当 $S_{ij}>0$ 时, $l(x_i)=l(x_j)$, $Co(l(x_i), l(x_j))=0$.可见,公式(6)恒等于 0.因此,CSLPP 在监督近邻图下是不工作的.

2 加权代价敏感局部保持降维

2.1 加权局部保持降维

在人脸识别的门禁系统中,人脸数据集是类别不平衡的.假设第 C 类为入侵者,其他 $C-1$ 类为合法者.由公式

(5)可知,当 C 类的样本数远大于其他任何一类时,特征分解矩阵 A 将被第 C 类的协方差矩阵 A_C 所决定.因此,对 A 进行特征分解得到的投影向量 w 只能体现第 C 类的局部保持性质,其他 $C-1$ 类的局部保持性质将得不到保持.为了提高少数类的局部保持能力,我们采用一种加权的策略:取每类样本的协方差矩阵 $A_i, i=1, \dots, C$ 迹的 τ 次方的倒数作为第 i 类的权重,使得多数类的权重较小,少数类的权重较高.具体的加权函数的定义如下:

$$\gamma_i = 1/\text{tr}(A_i)^\tau, i=1, \dots, C \quad (8)$$

其中, $\text{tr}(A_i)$ 表示协方差矩阵 $A_i = \sum_{p=1}^{N_i} \sum_{q=1}^{N_i} (x_p - x_q)(x_p - x_q)^T S_{pq}$ 的迹; τ 是参数,用于度量对多数类样本的惩罚程度. τ 值越大,说明对多数类的惩罚越大;当 $\tau=0$ 时, $\gamma_i=1, i=1, \dots, C$, 即不采用加权方法.

2.2 代价敏感的局部保持降维

假设属于同类且满足近邻关系的两样本 x_i, x_j , 它们投影后的距离表示为 $d(x_i, x_j) = \|w^T x_i - w^T x_j\|^2$. $d(x_i, x_j)$ 反映了原空间同类近邻样本投影后的近邻程度. $d(x_i, x_j)$ 越小, 说明原空间同类近邻样本投影后依然是近邻的, 两样本分为同类的可能性就越大, x_i 错分成其他类的可能性也就越小; $d(x_i, x_j)$ 越大, 说明原空间同类近邻样本投影后是分散的, 不再近邻保持, 两样本被分为同类的可能性就越小, x_i 被错分成其他类的可能性也就越大. 因此, $d(x_i, x_j)$ 体现了投影后样本 x_i 错分成其他类的错分量, $d(x_i, x_j)$ 越小, 表示将样本 x_i 错分成其他类的错分量越小; $d(x_i, x_j)$ 越大, 表示将样本 x_i 错分成其他类的错分量越大.

为了更准确地度量 x_i 的错分量, 我们采用离 x_i 最近的 k 个同类样本来度量样本 x_i 的错分量, 离 x_i 最近的样本的权重最大, 离 x_i 最远的样本的权重最小. 因此, 我们得到样本 x_i 的错分量:

$$\varepsilon_i = \sum_{x_j \in knn(x_i) \text{ and } l(x_i) \neq l(x_j)} \beta_{ij} d(x_i, x_j),$$

其中, β_{ij} 表示 x_i 的近邻样本 x_j 的权重. 如果 $x_j \notin knn(x_i)$ 或者 $l(x_i) = l(x_j)$, 那么 $\beta_{ij} = 0$, 则 $\varepsilon_i = \sum_{j=1}^N \beta_{ij} d(x_i, x_j)$.

通过简单推广, 我们可以得到整体错分量最小化的模型:

$$\min : \sum_{i=1}^N \sum_{j=1}^N \beta_{ij} d(x_i, x_j) = \sum_{i=1}^N \sum_{j=1}^N \beta_{ij} \|w^T x_i - w^T x_j\|^2 \quad (9)$$

如果令 $\beta_{ij} = S_{ij}$, 公式(9)和公式(1)是等价的. 可见, LPP 模型本质上追求整体错分量的最小化.

在人脸识别中, 不同的错分其代价是不同的. ε_i 表示将样本 x_i 错分成其他类的错分量. 我们将 ε_i 乘以对应的错分代价 $Co(l(x_i), \cdot)$, 得到一个整体错分代价最小化的 LPP 模型:

$$\min : \sum_{i=1}^N Co(l(x_i), \cdot) \varepsilon_i \quad (10)$$

在两类问题中, 将样本 x_i 错分成其他类的代价 $Co(l(x_i), \cdot)$, 可以直接由代价矩阵 Co 得到(两类问题: p 和 q , 其中 p 类错分成其他类的代价就是 $Co(p, q)$, 反之亦然). 在多类问题中, 代价 $Co(l(x_i), \cdot)$ 不能由代价矩阵直接得到. 我们采用文献[24]中的方法计算出对应的错分代价:

$$Co(l(x_i), \cdot) = \sum_{k=1}^C Co(l(x_i), k) \quad (11)$$

根据公式(11), 我们可以改写公式(10), 得到整体错分代价最小化的 LPP 模型:

$$\min : \sum_{i=1}^N Co(l(x_i), \cdot) \varepsilon_i = \sum_{i=1}^N \sum_{k=1}^C Co(l(x_i), k) \varepsilon_i \quad (12)$$

2.3 加权代价敏感局部保持降维

在人脸识别的 identification 模式下, 综合考虑类别不平衡以及代价敏感问题, 本文提出了一种加权代价敏感局部保持降维方法(weighted cost sensitive locality preserving projection, 简称 WCSLPP), 其模型描述如下:

$$\begin{aligned}
\min_w: \sum_{i=1}^N \sum_{j=1}^N \alpha_{ij} \|w^T x_i - w^T x_j\|^2 S_{ij} &= \sum_{p=1}^C \sum_{q=1}^{N_p} \sum_{i=1}^{N_q} \alpha_{ij} \|w^T x_i - w^T x_j\|^2 S_{ij} \\
&= w^T \sum_{p=1}^C \sum_{i=1}^{N_p} \sum_{j=1}^{N_p} \alpha_{ij} \|x_i - x_j\|^2 S_{ij} w
\end{aligned} \quad (13)$$

其中,

$$\begin{aligned}
S_{ij} &= \begin{cases} \exp(-\|x_i - x_j\|^2 / \delta^2), & l(x_i) = l(x_j) \text{ and if } x_i \in knn(x_j) \text{ or } x_j \in knn(x_i), \\ 0, & \text{otherwise} \end{cases} \\
\alpha_{ij} &= \begin{cases} Co(k, \cdot) \gamma_k, & l(x_i) = l(x_j) = k, k = 1, \dots, C \\ 0, & l(x_i) \neq l(x_j) \end{cases}, \\
Co(k, \cdot) &= \sum_{i=1}^C Co(k, i) \gamma_k = 1 / \text{tr} \left(\sum_{p=1}^{N_k} \sum_{q=1}^{N_k} (x_p - x_q)(x_p - x_q)^T S_{pq} \right)^{\tau}.
\end{aligned}$$

如果 $\alpha_{ij} = \gamma_k$, 公式(13)就退化为加权局部保持降维方法; 如果 $\tau = 0$, $\alpha_{ij} = Co(k, \cdot)$, 公式(13)就退化为代价敏感的局部保持降维方法(公式(12)); 如果 $\alpha_{ij} = 1$, 公式(13)就退化为传统的局部保持降维方法^[11].

3 实验

3.1 数据集描述

本文采用人脸数据集 AR^[14], PIE^[3], Extended Yale B^[15] 对算法进行验证, 各数据集的具体描述见表 2.

Table 2 Detailed descriptions of face datasets

表 2 人脸数据集的详细描述

数据集	样本个数	类别数	每类样本个数	样本的大小
AR	1 400	100	14	66×48
PIE	11 554	68	170	32×32
Extended Yale B	2 414	38	64	32×32

3.2 实验设置

为了接近真实的人脸识别系统, 在实验中, 合法者的类别数设置为 $M_{AR}=20, M_{PIE}=18, M_{Extended \text{ Yale B}}=14$ 或者 $M_{AR}=99, M_{PIE}=67, M_{Extended \text{ Yale B}}=37$, 剩余样本为入侵者 I ; 错分代价和文献[9,12]中一致: $Co(I, G)=20, Co(G, I)=2, Co(G, G)=1$. 在 AR, PIE, Extended Yale B 数据集中, 每类分别选择 7, 50, 30 张作为训练集, 剩余图片作为测试集. 分类器采用 KNN 和代价敏感的 MCKNN^[9], k 值取 3. 实验重复 10 次, 取平均. 具体实验设置见表 3.


Table 3 Experimental settings

表 3 实验设置

数据集	实验设置 1		实验设置 2		每类合法者的 样本数 N_G	每类入侵者的 样本数 N_I	错分代价比 $Co(I, G):Co(G, I):Co(G, G)$
	合法者 类别数 M	入侵者 类别数 I	合法者 类别数 M	入侵者 类别数 I			
AR	20	80	99	1	7	7	20:2:1
PIE	18	50	67	1	50	50	20:2:1
Extended Yale B	14	24	37	1	30	30	20:2:1

3.3 参数 τ 对算法性能的影响

为了检验参数 τ 对算法性能的影响, 本文在实验设置 1 下, 通过变换 τ 的值 ($\tau=0.0.2:2$), 检验算法 WCSLPP 的性能. 实验中采用的评价指标为整体错分代价 $Cost$. 实验结果如图 1 所示. 由图 1 可以看出, 当 $\tau=0$ 或者 τ 过大时, 算法 WCSLPP 的错分代价较高, 这说明不考虑类别加权或过分考虑类别加权都将影响算法的性能, 都是不可取的; 在 AR, PIE, Extended Yale B 数据集上, τ 分别选取 $[0.8, 1], 0.6, [0.8, 1]$ 比较合适.

Fig.1 Misclassification costs of WCSLPP vs. τ 图 1 WCSLPP 在不同 τ 值下的错分代价

3.4 人脸识别结果

3.4.1 入侵者多于合法者情形下的人脸识别结果

本文在实验设置 1 下对算法性能进行了验证.我们分别与以下 3 种算法进行比较:(1) 采用无监督近邻图的 LPP 算法(LPP_Un)^[11];(2) 采用监督近邻图的 LPP 算法(LPP)^[11];(3) 代价敏感的局部保持降维(CSLPP)^[12].实验采用 5 种评价准则:(1) 整体错分代价 $Cost$;(2) 将入侵者错分成合法者的比例 $ErrIG$;(3) 将合法者错分成入侵者的比例 $ErrGI$;(4) 将合法者错分成其他合法者的比例 $ErrGG$;(5) 整体的错误率 Err .在 AR,PIE,Extended Yale B 数据集上, τ 分别选取 1,0.6,1.由表 4 可知,算法 WCSLPP 在全部 3 个数据集、5 种评价指标以及 2 种分类器上的分类结果都要优于其他 3 种算法.WCSLPP 降低整体错分代价的主要原因在于,WCSLPP 的目标函数满足错分代价最小化准则;降低 $ErrIG$ 的原因在于,我们给不同的错分赋予了不同的错分代价;降低 Err , $ErrGI$ 以及 $ErrGG$ 的原因在于,WCSLPP 采用加权策略平衡了各类样本对投影方向的贡献,提高了少数类样本的局部保持能力.

Table 4 Face recognition results on Experimental Setting 1

表 4 实验设置 1 下的人脸识别结果

		AR		PIE		Extended Yale B	
		KNN	MCKNN	KNN	MCKNN	KNN	MCKNN
$Cost$	LPP_Un	737.5	432.1	10 650	8 753	1 993.8	1 211.8
	CSLPP	577.7	3 741.1	11 767	75 218	3 104.9	6 234.2
	LPP	111.4	111.6	2 530	2 615	177.1	178.9
	WCSLPP	35.4	35.4	549	554.9	67.6	67.7
$ErrIG$ (%)	LPP_Un	4.11	1.66	5.56	4.21	6.47	3.08
	CSLPP	2.19	25.06	4.72	44.33	9.09	21.61
	LPP	0.21	0.21	1.16	1.2	0.42	0.42
	WCSLPP	0.04	0.04	0.19	0.196	0.078	0.078 1
$ErrGI$ (%)	LPP_Un	10.7	13.76	8.74	10.8	10.8	15.46
	CSLPP	19.01	13.36	23.63	10.24	26.76	22.09
	LPP	5.76	5.71	3.81	3.84	2.57	2.54
	WCSLPP	2.1	2.1	1.42	1.42	1.81	1.81
$ErrGG$ (%)	LPP_Un	1.67	1.07	1.85	1.53	5.54	2.5
	CSLPP	0.79	6.04	2.63	15.33	8.41	12.98
	LPP	0.11	0.23	0.28	0.39	0.45	0.49
	WCSLPP	0	0	0.022	0.025	0.13	0.13
Err (%)	LPP_Un	16.49	16.49	16.15	16.53	22.81	21.04
	CSLPP	21.99	44.73	30.99	69.91	44.25	56.68
	LPP	6.09	6.16	5.25	5.43	3.43	3.45
	WCSLPP	2.14	2.14	1.632	1.641	2.01	2.02

3.4.2 合法者多于入侵者情形下的人脸识别结果

本文在实验设置 2 下对算法性能进行了验证.我们采用和第 3.4.1 节相同的对比方法、评价准则、分类器.

在 AR,PIE,Extended Yale B 数据集上,采用 10 折叠交叉验证的方法, τ 分别设置为 3.9,1.6,1. 实验结果见表 5. 由表 5 可知,WCSLPP 除了在 AR 数据集上的识别结果略差于监督的 LPP 算法以外,在全部 3 个数据集、5 种评价指标以及 2 种分类器上的分类结果都要优于其他 3 种算法. 这说明,本文算法 WCSLPP 不仅能够应用于入侵者多于合法者情形下的人脸识别问题,还能够应用于合法者多于入侵者情形下的人脸识别问题.

Table 5 Face recognition results on Experimental Setting 2

表 5 实验设置 2 下的人脸识别结果

		AR		PIE		Extended Yale B	
		KNN	MCKNN	KNN	MCKNN	KNN	MCKNN
<i>Cost</i>	LPP_Un	426.5	471	3 210	3 531.4	810.7	748.1
	CSLPP	619.4	650	5 235	6 333	1 291.7	1 282.2
	LPP	23.6	22.4	443.7	470.7	79.9	77.2
	WCSLPP	37.8	39.5	393.4	408.1	52.9	52.6
<i>ErrIG (%)</i>	LPP_Un	0.64	0.45	0.52	0.4	1.14	0.77
	CSLPP	0.87	0.75	0.806	0.806	1.66	1.3
	LPP	0.057	0.042	0.057	0.055	0.14	0.13
	WCSLPP	0.085	0.85	0.041	0.039	0.054	0.054
<i>ErrGI (%)</i>	LPP_Un	0.9	3.34	0.48	1.4	0.65	1.93
	CSLPP	1.9	1.48	0.92	2.28	1.71	5.71
	LPP	0.042	0.057	0.045	0.1	0.031	0.039
	WCSLPP	0.014	0.014	0.034	0.067	0.007 8	0.007 8
<i>ErrGG (%)</i>	LPP_Un	46.2	51.4	27.8	32.3	39.3	39.3
	CSLPP	67.2	74.7	46.2	56.9	64.6	63.1
	LPP	2.14	2.22	4.19	4.46	3.22	3.31
	WCSLPP	3.65	3.9	3.92	4.08	3.03	3.01
<i>Err (%)</i>	LPP_Un	47.8	55.2	28.8	34.1	41.2	42
	CSLPP	70	76.9	47.9	60	68	70.1
	LPP	2.24	2.32	4.3	4.62	3.4	3.48
	WCSLPP	3.75	4	3.99	4.19	3.1	3.07

3.4.3 WCSLPP 和 MCKNN 的人脸识别效果比较

Zhou 等人将样本的代价信息融入到人脸识别的分类部分,提出了 MCKNN 分类器^[9],而本文算法 WCSLPP 将样本的代价信息融入到了降维部分. 本文在表 3 的实验设置下对这两种识别方式进行了验证. 实验结果见表 6,其中,WCSLPP+KNN 表示采用代价敏感的降维方法 WCSLPP,KNN 分类器进行识别;LPP+MCKNN 表示采用 LPP 的降维方法,代价敏感的分类器 MCKNN 进行识别. 观察表 6 可知,WCSLPP+KNN 的识别方式除了在实验设置 2 的 AR 数据集上的识别结果略差于 LPP+MCKNN 的识别方式以外,在两种实验设置和全部 3 个数据集上的识别结果都要优于 LPP+MCKNN 的识别方式. 这很有可能是由于采用 LPP 降维后的数据丢失了一些重要的代价信息,导致代价敏感的分类器得到了局部最优的分类结果^[12].

Table 6 Comparison of two face recognition modes

表 6 两种人脸识别方式的识别效果比较

	实验设置 1			实验设置 2		
	AR	PIE	Extended Yale B	AR	PIE	Extended Yale B
WCSLPP+KNN	35.4	549	67.6	37.8	393.4	52.9
LPP+MCKNN	111.6	2615	178.9	22.4	470.7	77.2

3.5 实验参数的变化对算法性能的影响

3.5.1 算法在不同的合法者类别数下的性能比较

为了检验算法在不同的合法者类别数下的性能,本文固定 $Co(I,G):Co(G,I):Co(G,G)=20:2:1$,通过变化合法者的类别数,检验算法的性能. 实验中采用的评价指标为整体错分代价 $Cost$. AR,PIE,Extended Yale B 数据集中合法者的类别数分别为 $M_{AR}=5:5:30, M_{PIE}=5,8,13,18,23,28, M_{Extended\ Yale\ B}=2:3:20$. 实验结果如图 2、图 3 所示. 从图中可以看出,WCSLPP 在不同的合法者类别数下都取得了较低的错分代价.




Fig.2 Comparison of total misclassification costs of different gallery persons with KNN classifiers

图 2 采用 KNN 分类器,不同的合法者类别数下的整体错分代价比较




Fig.3 Comparison of total misclassification costs of different gallery persons with MCKNN classifiers

图 3 采用 MCKNN 分类器,不同的合法者类别数下的整体错分代价比较

3.5.2 算法在不同的错分代价比下的性能比较

为了检验算法在不同错分代价下的性能,本文固定 $Co(G,I)=2, Co(G,G)=1$, 通过变化 $Co(I,G)$ 的值, 观察算法的性能. 实验中采用的评价指标为整体错分代价 $Cost$, 采用 KNN 分类器. $Co(I,G)$ 的值设置为 2, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50. 实验结果如图 4 所示. 从图 4 中可以看出, WCSLPP 在不同的错分代价下都取得了较低的错分代价. 在图 4(a)以及图 4(c)中, 当 $Co(I,G)>35$ 以后, WCSLPP 的错分代价趋于稳定. 这是由于在 WCSLPP 中 $ErrIG=0$, 所以 WCSLPP 的错分代价不随 $Co(I,G)$ 值的改变而改变.




Fig.4 Comparison of total misclassification costs with different misclassification cost ratios

图 4 不同错分代价比下的整体错分代价比较

3.6 算法的执行时间

实验采用 Matlab R2009 软件,使用的电脑配置如下:2.83GHz CPU,2G RAM.在表 3 的实验设置下,采用 KNN 分类器,算法的训练时间和测试时间见表 7.表 7 表明,WCSLPP 的训练时间、测试时间低于 CSLPP,与 LPP 以及 LPP_Un 是可比较的.

Table 7 Comparison of time costs (s)

表 7 算法的时间复杂度比较 (秒)

		LPP_Un	CSLPP	LPP	WCSLPP
AR	训练时间	5.391 7	6.7387	5.262 2	6.166 2
	测试时间	0.184 3	0.332	0.169 7	0.169 5
PIE	训练时间	3.08	4.3425	2.588 4	3.691 5
	测试时间	13.131 6	23.2701	13.941	13.863 2
Extended Yale B	训练时间	1.440 6	2.172	1.440 7	1.559 9
	测试时间	0.991 5	1.252 8	0.988 4	0.984 3

4 结束语

本文提出了一种面向人脸识别的加权代价敏感局部保持降维方法 WSCLPP.一方面,该方法平衡了各类样本对投影方法的贡献,提高了少数类样本的局部保持能力;另一方面,该方法又将错分代价融入 LPP 模型中,使其满足错分代价最小化准则,降低了分类的整体错分代价.在人脸数据集 AR,PIE,Extended Yale B 上的实验结果表明了算法的有效性.

在真实的人脸识别问题中,错分代价很难得到.因此,自适应地学习出样本的错分代价,是未来的一个主要研究方向.


References:

- [1] Ahonen T, Hadid A. Face description with local binary patterns: Application to face recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2006,28(12):2037–2044. [doi: 10.1109/TPAMI.2006.244]
- [2] Belhumeur PN, Hespanha J. Eigenfaces vs. Fisherfaces: Recognition using specific linear projection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1997,19(7):711–720. [doi: 10.1109/34.598228]
- [3] Turk M, Pentland A. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 1991,3(1):71–86. [doi: 10.1162/jocn.1991.3.1.71]
- [4] Zhao W, Chellappa R, Phillips PJ. Face recognition: A literature survey. *ACM Computing Surveys*, 2003,35(1):399–458. [doi: 10.1145/954339.954342]
- [5] He XF, Yan SC, Hu YX, Niyogi P, Zhang HJ. Face recognition using Laplacianfaces. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2005,27(3):328–340. [doi: 10.1109/TPAMI.2005.55]
- [6] Wright J, Yang Y, Sastry S, Ma Y. Robust face recognition via sparse representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2009,31(2):210–227. [doi: 10.1109/TPAMI.2008.79]
- [7] Su Y, Guang SS, Chen XL. Integration of global and local feature for face recognition. *Ruan Jian Xue Bao/Journal of Software*, 2010,21(8):1849–1862 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3627.htm> [doi: 10.3724/SP.J.1001.2010.03627]
- [8] Yang LP, Gong WG, Gu XH, Li WH, Du X. Complete discriminant locality preserving projections for face recognition. *Ruan Jian Xue Bao/Journal of Software*, 2010,21(6):1277–1286 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3482.htm> [doi: 10.3724/SP.J.1001.2010.03482]
- [9] Zhang Y, Zhou ZH. Cost-Sensitive face recognition. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2010,32(10):1758–1769. [doi: 10.1109/TPAMI.2009.195]
- [10] Jain AK, Ross A, Prabhakar S. An introduction to biometric recognition. *IEEE Trans. on Circuits and Systems for Video Technology*, 2004,14(1):4–20. [doi: 10.1109/TCSVT.2003.818349]

- [11] He XF, Niyogi P. Locality preserving projections. In: Sebastian T, Lawrence KS, Bernhard S, eds. Proc. of the Advances in Neural Information Processing Systems. Vancouver, Whistler: MIT Press, 2003. 153–160.
- [12] Liu JW, Tan YP. Cost-Sensitive subspace learning for face recognition. In: Mortensen EN, Yang MH, eds. Proc. of the IEEE Int'l Conf. on Computer Vision and Pattern Recognition. San Francisco: IEEE Computer Society, 2010. 2661–2666. [doi: 10.1109/CVPR.2010.5539983]
- [13] Qiao LS, Chen SC, Tan XY. Sparsity preserving projections with applications to face recognition. Pattern Recognition, 2010,43(1): 331–341. [doi: 10.1016/j.patcog.2009.05.005]
- [14] Martinez AM, Kak AC. PCA versus LDA. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2001,23(2):228–233. [doi: 10.1109/34.908974]
- [15] Georgiades AS, Belhumeur PN, Kriegman DJ. From few to many: Illumination cone models for face recognition under variable lighting and pose. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2001,23(6):643–660. [doi: 10.1109/34.927464]
- [16] Cai D, He XF, Han JW. Semi-Supervised discriminant analysis. In: Walter S, ed. Proc. of the IEEE Int'l Conf. on Computer Vision. Rio de Janeiro: IEEE, 2007. 1–7. [doi: 10.1109/ICCV.2007.4408856]
- [17] Cai D, He XF, Zhou K. Locality sensitive discriminant analysis. In: Manuela MV, ed. Proc. of the Int'l Joint Conf. on Artificial Intelligence. Hyderabad, 2007. 1713–1726.
- [18] Hu HF. Orthogonal neighbourhood preserving discriminant analysis for face recognition. Pattern Recognition, 2008,41(6): 2045–2054. [doi: 10.1016/j.patcog.2007.10.029]
- [19] Kokiopoulou E, Saad Y. Orthogonal neighbourhood preserving projections: A projection-based dimensionality reduction technique. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2007,29(12):2143–2156. [doi: 10.1109/TPAMI.2007.1131]
- [20] Kokiopoulou E, Saad Y. Enhanced graph-based dimensionality reduction with repulsion Laplaceans. Pattern Recognition, 2009, 42(11):2392–2402. [doi: 10.1016/j.patcog.2009.04.005]
- [21] Yang B, Chen SC. Sample-Dependent graph construction with application to dimensionality reduction. Neurocomputing, 2010, 74(3):301–314. [doi: 10.1016/j.neucom.2010.03.019]
- [22] Yu W, Teng X, Liu C. Face recognition using discriminant locality preserving projections. Image and Vision Computing, 2006, 24(3):2398–248. [doi: 10.1016/j.imavis.2005.11.006]
- [23] Zhang L, Qiao LS, Chen SC. Graph-Optimized locality preserving projections. Pattern Recognition, 2010,43(6):1993–2002. [doi: 10.1016/j.patcog.2009.12.022]
- [24] Ting KM. An instance-weighting method to induce cost-sensitive trees. IEEE Trans. on Knowledge and Data Engineering, 2002, 14(3):659–665. [doi: 10.1109/TKDE.2002.1000348]

附中文参考文献:

- [7] 苏煜,山世光,陈熙霖,高文.基于全局和局部特征集成的人脸识别.软件学报,2010,21(8):1849–1862. <http://www.jos.org.cn/1000-9825/3627.htm> [doi: 10.3724/SP.J.1001.2010.03627]
- [8] 杨利平,龚卫国,辜小花,李伟红,杜兴.完备鉴别保局投影人脸识别算法.软件学报,2010,21(6):1277–1286. <http://www.jos.org.cn/1000-9825/3482.htm> [doi: 10.3724/SP.J.1001.2010.03482]



万建武(1986—),男,江苏常州人,博士生,主要研究领域为数据挖掘,机器学习,模式识别.

E-mail: xiaowunjnu@163.com



杨明(1964—),男,博士,教授,博士生导师,主要研究领域为数据挖掘,机器学习,模式识别.

E-mail: myang@njnu.edu.cn



吉根林(1964—),男,博士,教授,博士生导师,主要研究领域为数据库,数据挖掘技术.

E-mail: glji@njnu.edu.cn



陈银娟(1986—),女,硕士,主要研究领域为软件缺陷预测,机器学习.

E-mail: brandycyj@163.com