

分块二维局部保持鉴别分析在人脸识别中的应用

赵春晖 陈才扣

(扬州大学信息工程学院 扬州 225002)

摘 要 局部保持鉴别分析在人脸识别研究中具有非常重要的地位。在此基础上提出的 2DLPDA 算法直接在二维空间进行运算,一定程度上提高了性能。但是当样本在光照阴影、遮挡等情况下时,识别率受到很大影响,为此提出一种改进的算法,即分块二维局部保持鉴别分析方法。其将样本分块,以更好地提取样本中的局部近邻特征。这样同一样本的不同分块在选择近邻时,就可能具有来自不同样本的近邻,从而能更好地提取样本的局部特征。最后将局部特征整合为整体作为识别的依据。在 AR、YALE 及 ORL 库上验证了算法的有效性。

关键词 人脸识别,模式识别,特征抽取,局部保持投影,分块算法,最大间距准则

中图分类号 TP391.41 **文献标识码** A

Modular Two-dimensional Locality Preserving Discriminant Analysis and its Application in Human Face Recognition

ZHAO Chun-hui CHEN Cai-kou

(College of Information Engineering, Yangzhou University, Yangzhou 225002, China)

Abstract Locality preserving discriminant analysis takes very important position in face recognition research. Based on this, the 2DLPDA method was proposed, which directly processes the operation in the two dimensional space. In some way, it improves the performance of the algorithm. But the problem of the sensitivity to such variations like lighting, expression and occlusion will make a big influence on the recognition rate when using 2DLPDA method. We proposed an improved algorithm called modular two-dimensional locality preserving discriminant analysis method. We divided the sample in blocks, so that we could extract the local neighborhood of the sample better. Because each sample was divided into blocks, the different blocks of one sample may have different nearest neighbors, causing local features of the sample to be extracted better. At the end of the method, all the local features are integrated together to be the basis for the identification. Experimental results on AR, YALE and ORL face databases show that the proposed method outperforms the 2DLPDA method.

Keywords Face recognition, Pattern recognition, Feature extraction, Locality preserving projection, Modular method, Maximum margin criterion

1 引言

人脸识别是模式识别领域的一个很重要的课题。其中特征提取在人脸识别中是不可或缺的环节。特征提取的目标是从高维数据中提取出能有效体现出数据特征的低维数据,用于人脸的识别与检测。在人脸识别中,特征提取的降维算法主要分为线性算法和非线性算法。其中主成分分析(Principle Component Analysis, PCA)^[1]方法(又称 K-L 变换)及线性鉴别分析(Linear Discriminant Analysis, LDA)^[2]方法被认为是最经典的线性特征提取算法,并且被广泛地应用于高维数据的降维。其主要思想将人脸空间视为线性空间,训练样本寻找到最优的降维投影轴向量组,采用线性运算将高维空间数据通过投影降维到低维空间。线性算法能很好地提取数据的全局特征,但是不能很好地提取数据的局部非线性的结构。为此产生了诸如流形学习方法等非线性降维算法,流形

学习试图发现高维人脸数据的某非线性低维流形结构。为此产生了等距映射(ISO metric Mapping, ISOMAP)^[3]、拉普拉斯特征映射(Laplacian Eigenmaps, LE)^[4]、局部线性嵌入(Locally Linear Embedding, LLE)^[5]等算法。但是,由于流形方法应用于人脸识别时存在 Out-of-sample 问题^[6],利用流形学习算法的线性化可以解决这个问题。为此产生了局部保持投影(Locally Preserving Projection, LPP)^[7]、边界 Fisher 分析(Marginal Fisher Analysis, MFA)^[8]等流形学习算法,这类方法通过保留数据的局部邻域信息,来提取数据中内在的低维非线性局部结构。但上述算法需将图像矩阵列向量化,所以会破坏图像的几何结构,且转换后向量维数高,计算代价大。为此产生了 2DPCA^[9]和 2DLDA^[10]算法,此类方法无需将图像转换为列向量,直接在图像空间进行计算,做到了不破坏样本的局部结构,且避免了向量高维空间存在的奇异问题,很大程度上提高了算法的效率。文献[11]提出一种二维局部保持

赵春晖(1989—),男,硕士生,主要研究方向为模式识别、人工智能,E-mail:zch2009hytc@163.com(通信作者);陈才扣(1967—),男,博士,教授,主要研究方向为模式识别、机器学习、计算机视觉、鉴别分析、生物特征识别。

鉴别分析 (Two-dimensional Locality Preserving Discriminant Analysis, 2DLPDA) 特征提取算法。该算法直接在图像矩阵空间进行运算, 其吸收了 ONPDA^[12] 算法思想, 在 LPP 的基础上利用训练样本类别信息计算二维样本类内及类间散布矩阵, 并在 2DLPDA 的目标函数中引入最大间距准则 (Maximum Margin Criterion, MMC) 来求得最佳鉴别投影向量; 同时直接在二维图像空间进行运算, 避免了小样本情况下矩阵奇异问题。但在研究中发现, 该算法虽然很好地提高了人脸识别的成功率, 但是当遇到人脸图像存在光照阴影、遮挡等问题时, 上述算法的识别率受到很大影响。为此本文提出一种分块二维局部保持鉴别分析方法 (Modular Two-dimensional Locality Preserving Discriminant Analysis, M2DLPDA), 以试图解决该问题。M2DLPDA 将样本分块, 吸收 2DLPDA 在求取最优鉴别投影向量的优势, 独立地对样本分块后的各模块求取各自的投影向量。使用该策略后, 对于整体人脸, 其局部近邻是固定的。而引入分块后, 同一个样本的不同块的近邻可以来自不同的样本, 因此可以更好地提取出样本局部特征。之后根据各块的结果进行综合, 得出整幅样本图片之间的误差值, 并将其作为分类的判别条件。从而更好地解决原算法在样本存在光照阴影、遮挡等问题下识别性能较低的问题。本算法在 ORL 库、存在遮挡的 AR 库及存在阴影的 YALE 库上均有很好的识别效果, 从而验证了其有效性。

2 相关工作

2.1 LPP 算法

LPP 算法的目标是在降维的同时保持样本固有的局部性不变。即原始空间相邻的两个样本 $x_i, x_j \in R^n$, 通过转换矩阵 A 投影到 d 维特征空间后为 $y_i, y_j \in R^d$, 而 y_i, y_j 在特征空间也保持着近邻关系。LPP 目标函数定义为

$$A_{opt} = \frac{1}{2} \arg \min_A \left[\sum_{i,j} \|y_i - y_j\|^2 w_{ij} \right] \quad (1)$$

其中, w_{ij} 为 x_i, x_j 之间的近邻关系权重值, 定义为

$$w_{ij} = \begin{cases} e^{-\frac{\|x_i - x_j\|^2}{t}}, & x_i, x_j \text{ 为 } k \text{ 近邻} \\ 0, & \text{其他} \end{cases} \quad (2)$$

其中, t 为用于度量任意两样本 x_i, x_j 近邻关系的固值参数。

对目标函数(1)进行化简

$$\begin{aligned} A_{opt} &= \frac{1}{2} \arg \min_A \left[\sum_{i,j} \|y_i - y_j\|^2 w_{ij} \right] \\ &= \frac{1}{2} \arg \min_A \left[\sum_{i,j} \|A^T x_i - A^T x_j\|^2 w_{ij} \right] \\ &= \frac{1}{2} \arg \min_A \operatorname{tr} \left(\sum_{i,j} (A^T x_i - A^T x_j) (A^T x_i - A^T x_j)^T \right) \\ &= \arg \min_A \operatorname{tr} \left(\sum_{i,j} (A^T X D X^T A - A^T X W X^T A) \right) \\ &= \arg \min_A \operatorname{tr} \left(\sum_{i,j} (A^T X L X^T A) \right) \end{aligned} \quad (3)$$

其中, $X = (x_1, x_2, \dots, x_N)$, W 是由 w_{ij} 构成的一个对称的权重矩阵。 D 为对角矩阵, $D_{ii} = \sum_j w_{ij}$; $L = D - W$ 为拉普拉斯矩阵。上式需满足低维结构对域的约束条件

$$A^T X D X^T A = 1 \quad (4)$$

使用拉格朗日乘子法, 式(3)、式(4)转化为求解广义特征值问题:

$$(X L X^T) A = \lambda (X D X^T) A \quad (5)$$

LPP 算法的最优投影方向 A 即为式(5)的最小 d 个特征值对应的特征向量。

2.2 2DLPDA 算法

设训练样本图像集为 $\{X_1, X_2, \dots, X_N\}$, 其中每个样本 $X_i \in R^{m \times n}$ ($i=1, 2, \dots, N$) 为一幅 $m \times n$ 像素的图像。 N 为训练样本的总数。令 $\varphi \in R^{n \times 1}$ 为 n 维投影向量, 任意训练样本通过 φ 投影得到一个 m 维列向量 $y = X\varphi$, 称为图像 X 的投影特征向量。

定义二维图像矩阵类间近邻关系权重 W_{ij}^B 和类内近邻关系权重 W_{ij}^W 分别为

$$W_{ij}^B = \begin{cases} \left(\frac{1}{N} - \frac{1}{N_C} \right) e^{-\frac{\|X_i - X_j\|^2}{t}}, & \text{若 } X_i, X_j \text{ 同属于 } C \text{ 类} \\ \frac{1}{N} e^{-\frac{\|X_i - X_j\|^2}{t}}, & \text{其他} \end{cases} \quad (6)$$

$$W_{ij}^W = \begin{cases} \frac{1}{N_C} e^{-\frac{\|X_i - X_j\|^2}{t}}, & \text{若 } X_i, X_j \text{ 同属于 } C \text{ 类} \\ 0, & \text{其他} \end{cases} \quad (7)$$

其中, $\|\cdot\|$ 为矩阵的 Frobenius 范数。

根据近邻关系权重定义训练样本集的二维类间散度矩阵 S_B 和类内散度矩阵 S_W 为

$$S_B = \sum_{i=1}^N \sum_{j=1}^N W_{ij}^B (X_i - X_j)^T (X_i - X_j) \quad (8)$$

$$S_W = \sum_{i=1}^N \sum_{j=1}^N W_{ij}^W (X_i - X_j)^T (X_i - X_j) \quad (9)$$

为了使同类样本相互靠近, 不同类样本尽量分离, 引入最大间距准则 (MMC) 来定义 2DLPDA 目标函数

$$\max \operatorname{tr}(\varphi^T (S_B - S_W) \varphi) \quad (10)$$

假设求得的最优投影向量集为 $\{\varphi_1, \varphi_2, \dots, \varphi_d\}$, 增加约束条件要求任意两个投影向量正交, 即 $\varphi_i^T \varphi_j = 0$ ($i \neq j, i, j = 1, 2, \dots, d$), 则目标函数改写为:

$$\begin{aligned} &\max \operatorname{tr}(\varphi^T (S_B - S_W) \varphi) \\ &\text{s. t. } \varphi_i^T \varphi_j = 0 \quad (i \neq j, i, j = 1, 2, \dots, d) \end{aligned} \quad (11)$$

利用拉格朗日乘子法, 上式最优解可转化为求解下式的特征值问题

$$(S_B - S_W) \varphi_k = \lambda \varphi_k \quad (12)$$

取 $S_B - S_W$ 前 d 个最大特征值对应的正交特征向量构成最佳投影向量。

任一人脸图像 X 投影到任一投影向量 φ_k 上

$$y_k = X \varphi_k, \quad k = 1, 2, \dots, d \quad (13)$$

通过式(13)可求得一组特征向量 y_1, y_2, \dots, y_d , 其构成的一个 $m \times d$ 的矩阵 $Y = [y_1, y_2, \dots, y_d]$ 称为人脸图像 X 的特征矩阵。

3 本文方法

3.1 分块二维局部保持鉴别分析

分块二维局部保持鉴别分析的基本思想是针对图像在阴影及遮挡等情况下算法识别率低而提出的一种新的算法。其吸收原算法的长处, 将图像分块后, 通过训练样本提取出图像局部近邻特征结构, 并且可以有效地将图像中阴影及遮挡等部分提取出, 以减少其对整体样本的影响。同时不同于整体近邻关系的结构, 其可以更好地发现图像内部的局部结构, 同时在提取出局部结构后, 将所有的结果进行综合, 作为整体样本的判别条件。

首先将 $m \times n$ 维样本图像 M 分成 $p \times q$ 块个子图像矩阵, 即

$$M = \begin{pmatrix} M_{11} & M_{12} & \cdots & M_{1q} \\ M_{21} & M_{22} & \cdots & M_{2q} \\ \cdots & \cdots & \cdots & \cdots \\ M_{p1} & M_{p2} & \cdots & M_{pq} \end{pmatrix} \quad (14)$$

其中, $M \in R^{m \times n}$, $M_{ij} \in R^{m_1 \times n_1}$, $p \times m_1 = m$, $q \times n_1 = n$ 。

分块后, 将相同位置的块构成一个新的样本集, 则原样本集产生 $p \times q$ 个样本子集, 每个样本子集表示为:

$$M_s = \{ (M_1^s)_s, \dots, (M_1^1)_s, \dots, (M_i^s)_s, \dots, (M_t^s)_s, \dots, (M_c^s)_s \} \quad (15)$$

其中, $s=1, 2, \dots, p$; $t=1, 2, \dots, q$, $(M_i^s)_s$ 表示第 i 类样本的第 s 幅图片中第 st 块。

对每个样本子集分别构建子集中的类间及类内近邻关系权重

$$(W_s^B)_{ij} =$$

$$\begin{cases} \left(\frac{1}{N} - \frac{1}{N_C} \right) e^{-\frac{\| (M_s)_i - (M_s)_j \|^2}{t}}, & \text{若 } (M_s)_i, (M_s)_j \text{ 同属于} \\ & \text{C 类} \\ \frac{1}{N} e^{-\frac{\| (M_s)_i - (M_s)_j \|^2}{t}}, & \text{其他} \end{cases} \quad (16)$$

$$(W_s^W)_{ij} =$$

$$\begin{cases} \frac{1}{N_C} e^{-\frac{\| (M_s)_i - (M_s)_j \|^2}{t}}, & \text{若 } (M_s)_i, (M_s)_j \text{ 同属于 C 类} \\ 0, & \text{其他} \end{cases} \quad (17)$$

由近邻系数, 构建样本子集类间近邻关系散布矩阵及类内近邻散布矩阵

$$(S_s)_B = \sum_{i=1}^N \sum_{j=1}^N (W_s^B)_{ij} ((M_s)_i - (M_s)_j)^T ((M_s)_i - (M_s)_j) \quad (18)$$

$$(S_s)_W = \sum_{i=1}^N \sum_{j=1}^N (W_s^W)_{ij} ((M_s)_i - (M_s)_j)^T ((M_s)_i - (M_s)_j) \quad (19)$$

求出每个样本子集的正交投影向量矩阵 $\varphi_s = [\varphi_s^1, \varphi_s^2, \dots, \varphi_s^d]$, 以提取各个分块的流行结构。

3.2 特征提取及分类方法

对于所有训练样本的分块子集使用该子集相应的正交投影矩阵做投影, 得到新的样本子集为

$$\begin{aligned} M_s \varphi_s &= [(M_1^1)_s \varphi_k, \dots, (M_1^{n_1})_s \varphi_k, \dots, (M_i^1)_s \varphi_k, \dots, \\ & (M_t^1)_s \varphi_k, \dots, (M_c^{n_1})_s \varphi_k] \\ &= [(B_1^1)_s, \dots, (B_1^{n_1})_s, \dots, (B_i^1)_s, \dots, (B_t^1)_s, \dots, \\ & (B_c^{n_1})_s] = B_s \end{aligned} \quad (20)$$

假设待测样本为 Ψ , 对其进行 $p \times q$ 分块, 其第 st 分块子图像为 $(\Psi)_s$ 在特征空间 $\varphi_s = [\varphi_s^1, \varphi_s^2, \dots, \varphi_s^d]$ 的投影, 得到第 st 分块子图像的特征矩阵, 即

$$(\Psi)_s \varphi_s = (\Psi)_s [\varphi_s^1, \varphi_s^2, \dots, \varphi_s^d] = (Y)_s \in R^{m \times d} \quad (21)$$

计算所有训练样本 st 块子图像投影与测试样本 st 块子图像投影 $(Y)_s$ 的距离, 表示为

$$d((B_i^1)_s, (Y)_s) = \| (B_i^1)_s - (Y)_s \|_2 \quad (22)$$

求取所有训练样本和测试样本全部 $p \times q$ 块子图像投影的距离, 表示为

$$d((B_i^1)_s, Y) = \sum_{s=1}^p \sum_{t=1}^q \| (B_i^1)_s - (Y)_s \|_2 \quad (23)$$

分类识别过程中, 若 $d((B_i^1)_s, Y) = \min_i d((B_i^1)_s, Y)$, 则待测样本归属于第 C 类。

3.3 本文算法步骤

1) 将训练样本分成 $p \times q$ 块, 相同位置的块构成组成一个新的集合, 从而产生 $p \times q$ 个样本子集。

2) 针对每个相同位置块样本子集构建类间近邻关系权重 $(W_{ij}^B)_s$ 及类内近邻关系权重 $(W_{ij}^W)_s$, 这样就规避了由于样本整体性不能很好提取出局部近邻关系的问题。

3) 求取样本子集的类间近邻散布矩阵 $(S_s)_B$ 和类内近邻散布矩阵 $(S_s)_W$ 。

4) 求取每个样本子集的正交投影向量矩阵 $\varphi_s = [\varphi_s^1, \varphi_s^2, \dots, \varphi_s^d]$ 。

5) 将所有训练样本子集做投影后得到新的训练样本子集 $B_s = [(B_1^1)_s, \dots, (B_1^{n_1})_s, \dots, (B_i^1)_s, \dots, (B_t^1)_s, \dots, (B_c^{n_1})_s]$

6) 将测试样本分块后, 对每块做投影, 求取与该块对应的所有投影后训练样本的距离, 将测试样本每块与训练样本每块求出的距离求和, 作为总体的测试样本与训练样本间的距离, 找出有最小的距离值的训练样本所属分类即为测试样本分类。

4 实验结果与分析

4.1 实验一

首先采用 2×2 分块方式, 在有遮挡的 AR 库进行 3 组实验。第一组实验: 眼镜遮挡条件下的测试。在被眼镜遮挡的图像中, 眼镜约遮挡了人脸的 3%, 我们选取 AR 样本组中的第一组前 7 个无遮挡样本和第一组样本中被眼镜遮挡的 3 张图片中的 1 张作为训练样本, 测试的结果如图 1 所示(实验数据采集见表 1)。




图 1 眼镜遮挡条件下的识别率对比

表 1 AR 人脸库实验结果一

	2DPDA	2DLDA	2D-LPDA	Ours
5	0.6486	0.5861	0.6486	0.7292
10	0.6972	0.6319	0.6875	0.7403
15	0.7153	0.6347	0.6889	0.7444
20	0.7111	0.6431	0.6903	—
25	0.7000	0.6528	0.6917	—

第二组实验: 围巾遮挡条件下的测试。在被围巾遮挡的图像中, 围巾遮挡了约人脸的 50%, 我们选取 AR 样本组中的第一组前 7 个无遮挡样本和第一组样本中被围巾遮挡的 3 张图片中的 1 张作为训练样本, 测试的结果如图 2 所示(实验数据采集见表 2)。




图2 围巾遮挡条件下的识别率对比

表2 AR人脸库实验结果二

	2DPCA	2DLDA	2DLPDA	Ours
5	0.7139	0.7194	0.7403	0.7458
10	0.7583	0.7444	0.7514	0.7514
15	0.7639	0.7542	0.7500	0.7708
20	0.7694	0.7528	0.7542	—
25	0.7694	0.7458	0.7548	—

第三组实验:围巾和眼镜组合遮挡条件下的测试。我们选取AR样本组中的第一组前7个无遮挡样本、第一样本组中被眼镜遮挡的3张图片中的1张和第一样本组中被围巾遮挡的3张图片中的1张作为训练样本,测试的结果如图3所示(实验数据采集见表3)。




图3 眼镜与围巾遮挡组合条件下的识别率对比

表3 AR人脸库实验结果三

	2DPCA	2DLDA	2DLPDA	Ours
5	0.7368	0.7044	0.7176	0.7618
10	0.7544	0.7206	0.7294	0.7618
15	0.7574	0.7250	0.7279	0.7662
20	0.7662	0.7279	0.7309	—
25	0.7603	0.7373	0.7279	—

表1—表3分别列出了AR库上部分实验数据。从中可以看出,2DLPDA算法在有遮挡的条件下不能很好地展现出近邻结构的优势,因为遮挡的无序性很大程度地影响了实验结果,而引入分块算法后,其就能充分体现出近邻结构的优势。在第一组实验中,相比2DLPDA,新算法识别率提高了接近5%。第二组实验中最高的识别率比原算法提高了1.6%。第三组实验中,新算法识别率提高了3.5%。由此可以验证新算法相比原算法在有遮挡情况下提高了识别率,且是有效的。

4.2 实验二

在存在阴影的YALE库上采用 2×2 分块方式进行实验,分为2组,第一组选取每类样本组前3个样本作为训练样本,后8个样本作为测试样本,实验结果如图4所示(实验数据采集见表4)。

第二组选取每类样本组前5个样本作为训练样本,后6个样本作为测试样本,实验结果如图5所示(实验数据采集见表5)。




图4 YALE库实验一

表4 YALE人脸库实验结果一

	2DPCA	2DLDA	2DLPDA	Ours
5	0.8500	0.8333	0.8333	0.9167
10	0.8583	0.8667	0.8333	0.9167
15	0.8750	0.8667	0.8417	0.9167
20	0.8833	0.8750	0.8417	—
25	0.8833	0.8833	0.8417	—
30	0.8833	0.8833	0.8417	—




图5 YALE库实验二

表5 YALE人脸库实验结果二

	2DPCA	2DLDA	2DLPDA	Ours
5	0.9111	0.9333	0.9111	0.9444
10	0.9222	0.9222	0.9111	0.9444
15	0.9222	0.9222	0.9111	0.9333
20	0.9222	0.9222	0.9111	—
25	0.9222	0.9333	0.9111	—
30	0.9222	0.9333	0.9111	—

表4、表5分别列出了YALE库上部分实验数据。从中可以看出,2DLPDA算法在有阴影的条件下不能很好地展现出近邻结构的优势,引入分块算法后,其就能体现出近邻结构的优势。在第一组实验中,相比较2DLPDA,新算法提高了接近7.5%。第二组实验中,最高的识别率比原算法提高了3.3%。两组实验可以验证新算法相比原算法在受到光照阴影等情况下提高了识别率,且是有效的。

4.3 实验三

在无遮挡的ORL库上采用 4×2 分块方式进行实验,以验证分块对于原算法无遮挡条件下的有效性。实验分为2组,第一组从每类样本组选取3个样本作为训练样本,另外7个样本作为测试样本。实验结果如图6所示(实验数据采集见表6)。




图6 ORL库实验一

(下转第159页)

[11] 王梁, 吴斌, 方艳红. 基于区域生长和水平集的肝脏提取分割算法[J]. 科学技术与工程, 2014, 14(3): 216-221
 [12] 彭建喜. 一种基于 C 均值的模糊核聚类图像分割算法[J]. 电子技术, 2014, 38(9): 28-31
 [13] 陈启东, 程宜康, 石澄贤. 利用统计概率密度的活动轮廓模型分割图像[J]. 中国农机学报, 2014, 35(1): 112-117

[14] 刘建伟, 郭雷. 直方图的脑图像分割策略[J]. 西北工业大学学报, 2014, 34(3): 188-192
 [15] 王顺风, 阮晶, 王宇. 基于改进的 LBF 模型的图像分割[J]. 计算机应用与软件, 2011, 28(2): 25-27
 [16] 武园, 葛玉容. 一种基于脑部肿瘤 MR 图像的分割算法[J]. 电子设计工程, 2014, 22(10): 50-52
 [17] Bezdek J C. Pattern Recognition with Fuzzy Objective Function Algorithm[M]. New York: Springer-Verlag, 1981

(上接第 145 页)

表 6 ORL 人脸库实验结果一

	2DPCA	2DLDA	2DLPDA	Ours
5	0.8500	0.8750	0.8643	0.8770
10	0.8383	0.8500	0.8464	0.8679
15	0.8286	0.8500	0.8429	0.8679
20	0.8179	0.8393	0.8429	—
25	0.8179	0.8321	0.8429	—
30	0.8143	0.8321	0.8429	—

第二组选取每类样本组 5 个样本作为训练样本, 其余 5 个样本作为测试样本。实验结果如图 7 所示(实验数据采集见表 7)。




图 7 ORL 库实验二

表 7 ORL 人脸库实验结果二

	2DPCA	2DLDA	2DLPDA	Ours
5	0.9250	0.9150	0.9200	0.9350
10	0.9150	0.9200	0.9200	0.9350
15	0.9100	0.9150	0.9200	0.9350
20	0.9100	0.9150	0.9200	—
25	0.9100	0.9100	0.9200	—
30	0.9050	0.9100	0.9200	—

表 6、表 7 分别列出了 ORL 库上部分实验数据。从中可以看出, 新算法在无遮挡或者阴影的条件下相比较 2DLPDA, 也具有一定的优势。在第一组实验中, 相比较 2DLPDA, 新算法识别率提高了接近 1.27%。第二组实验中, 最高的识别率比原算法提高了 1.5%。两组实验可以验证新算法相比原算法在无遮挡或者阴影等情况下提高了识别率, 且是有效的。

结束语 本文提出的分块二维局部鉴别分析方法试图解决样本在遮挡及阴影等影响下的样本特征提取及识别问题。采用分块二维局部鉴别分析可以更好地提取样本局部特征, 使用该策略后, 对于同一个样本的不同块, 其近邻可以来自于不同的样本, 因此可以更好地提取出样本局部特征。之后根据各块的结果进行综合, 得出整幅样本图片之间的误差值, 并将其作为分类的判别原则。分块的方法对于样本局部特征提取算法的设计是一种非常好的思路。但是我们仍然不可忽略

的问题是所设计的算法必须针对用户需求选择最优的算法。对于样本整体性较好的系统, 可以选择体现样本整体性的算法, 而样本存在噪声且影响很大的时候, 引入分块算法可以更好地提取样本数据的有效信息。且对于不同的系统, 分块的数目在一定程度上影响着识别的效果。分块数目不是简单的越多越好, 所以在为系统设计分块算法时, 分块的数目也要根据实际系统的情况进行有效性验证。通过实验找到最有效的分块, 以使得系统性能最优。

参 考 文 献

[1] Turk M, Pentland A. Eigenface for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86
 [2] Belhumeur P N, Hespanha J P, Kriegman D J. Fisherfaces: Recognition Using Class Specific Linear Projection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720
 [3] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323
 [4] Belkin M, Niyogi P. Laplacian Eigenmaps for dimension reduction and data representation[J]. Neural Computation, 2001, 15(6): 1373-1396
 [5] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326
 [6] Bengio Y, Paiement J, Vincent P, et al. Out-of-sample extensions for LLE, Isomap, MDS, eigenmaps, and spectral clustering[J]. Neural Computation, 2004, 16(10): 2179-2219
 [7] He X F, Yan S C, Hu Y X, et al. Face recognition using laplacianfaces[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340
 [8] Yan S C, Xu D, Zhang B Y, et al. Graph embedding and extension: a general framework for dimensionality reduction[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(1): 40-51
 [9] Yang J, Yang J Y. From image vector to matrix: a straightforward image projection technique-IMPCA vs. PCA[J]. Pattern Recognition, 2002, 35: 1997-1999
 [10] Li M, Yuan B Z. 2D-LDA: A statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26: 527-532
 [11] 卢官明, 左加阔. 基于二维局部保持鉴别分析的特征提取算法[J]. 南京邮电大学学报(自然科学版), 2014, 34(5): 1-8
 [12] Hu H F. Orthogonal neighborhood preserving discriminant analysis for face recognition [J]. Pattern Recognition, 2008, 41: 2045-2054