

中图法分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2011)01-0066-06

论文索引信息: 张国印, 楼宋江. 无关性判别保局算法及其在人脸识别中的应用[J]. 中国图象图形学报, 2011, 16(1): 66-71

无关性判别保局算法及其在人脸识别中的应用

张国印, 楼宋江

(哈尔滨工程大学计算机科学与技术学院, 哈尔滨 150001)

摘要: 特征提取是人脸识别过程中的一个重要步骤, 是人脸识别算法有效性的关键。提出了一种基于无关性判别保局的特征提取算法, 并应用于人脸识别。基于保局投影算法的人脸识别是一种有效的人脸识别算法, 但它只考虑了数据的局部性, 没有考虑类别信息, 也没有考虑所提特征之间的相关性, 现有的改进算法虽然考虑了类别信息, 但是没有考虑到类间信息。本文算法使得所提特征之间相互无关, 这样降低了数据冗余, 同时考虑到类别信息, 使得投影后的类间区分度加强了。实验结果验证了算法的正确性和有效性, 比传统算法有较好的识别性能。

关键词: 特征提取; 保局投影; 无关性; 人脸识别

UDLP: an algorithm based on uncorrelated discriminant locality preserving and its application in face recognition

Zhang Guoyin, Lou Songjiang

(College of Computer Science and Technology, Harbin Engineering University, Harbin 150001 China)

Abstract: Feature extraction is an important and critical step in the process of face recognition, a feature extraction algorithm based on uncorrelated discriminant locality preserving is proposed, and its application in face recognition is carried out. Laplacianface which is based on locality preserving projection is an effective algorithm, but it only takes the locality into account, thus the extracted features might be highly correlated, and it does not consider the class information. Some improved algorithms consider the discriminant information, but the interclass information is not considered. The algorithm proposed here not only imposes an uncorrelated constraint to reduce data redundancy, but also utilizes the class information and the interclass separability after projection is enhanced. Experiments validate the correctness and effectiveness of the algorithm, and prove that the proposed algorithm has better performance.

Keywords: feature extraction; locality preserving projection; uncorrelated-ness; face recognition

0 引言

人脸识别由于其在监控、犯罪识别、人机交互等方面的广泛应用, 已成为模式识别研究领域的重要课题, 也是目前的一个研究热点^[1]。在过去的近 20 年里, 取得了很大的进步, 研究者相继提出了多种优秀算法, 其中基于子空间分析方法是人脸识别算法的主流方法之一, 但是在基于子空间分析时, 一般将一幅 $n \times m$ 像素的人脸图像看成是 $n \times m$ 维空间中

的一个向量, 因此在处理时的矩阵是高维的, 这样会引起维度灾难问题 (curse of dimensionality), 即在处理过程中, 所需数据量会随着维数的增多而成指数形式增长。解决这种问题的一个方法是取得足够多的样本, 但是这样不仅费时, 而且也不经济, 另外一个合理的做法是降维, 在人脸识别中称为特征提取, 即降维后的数据在低维空间中, 能使同类数据更加紧凑, 不同类的数据分布更加分散, 这样能更好地区分数据, 同时能去除噪音和压缩数据。

目前, 最流行的基于子空间的方法是

收稿日期: 2008-10-29; 修回日期: 2009-06-04

第一作者简介: 张国印 (1962—), 男, 教授。1997 年于哈尔滨工程大学获控制理论和控制工程专业博士学位, 主要研究方向为嵌入式、信息安全和模式识别。E-mail: zhangguoyin@hrbeu.edu.cn。

Eigenface^[2]、Fisherface^[3]和 Laplacianface^[4], 它们的核心算法分别是主成分分析 (PCA)^[5]、线性判别分析 (LDA)^[6]、保局投影 (LPP)^[7]。

较早出现的 2 个用于人脸识别的经典算法是 PCA 和 LDA。PCA 是在最小平方意义下给出数据的最优表征 (representation), 主要适用于图像的重构, 得到的是最具有表达力的子空间, 通过求解数据集协方差矩阵的最大几个特征值所对应的特征向量所张成的子空间而得到, 它没有考虑到样本的类别信息, 因此是一种非监督学习; LDA 是一种监督学习, 目标是求出一个线性子空间, 使得所有样本在这个子空间中, 类内样本散度最小, 类间样本的散度最大, 用它降维后的低维嵌入坐标非常有利于样本的分类。

以上两种算法都假定人脸图像存在于一个欧氏空间中, 最近有研究^[8-9]表明人脸图像存在于一个非线性的流形子空间中。目前已提出几种基于流形的非线性降维算法, 比如等距映射 (ISOMAP)^[8], 局部线性嵌入 (LLE)^[9], 拉普拉斯映射 (LE)^[10]。这些算法在数据的可视化方面比较优秀, 但是由于它们只考虑了训练集, 不能解决新样本的映射问题, 即所谓的“out of sample”问题, 同时也没有考虑类别信息, 因此不适合人脸识别等模式分类问题。基于这些缺点, HE 等人提出了 LPP 算法^[7], 该算法是 LE 的一个线性化版本, 因此它具有流形学习算法的一些特性, 同时它又是一线性映射, 能解决新样本的映射问题。

LPP 是继 PCA 和 LDA 的另一种有效算法, 针对原始 LPP 的一些不足, 目前已有研究对 LPP 进行改进, 比如 SLPP^[11]将类别信息进行考虑, 使之成为监督性学习; D-LPP^[12]对小样本问题引起的奇异性进行处理; OLPP^[13]将得到的基向量正交化, 使得投影后的样本的可区分度增加。虽然 LPP 算法应用于人脸识别时能取得比较满意的效果, 但是它是一种非监督学习算法, 没有考虑到样本的类别信息, 同时它求出的特征有可能是线性相关的, 这样就带有很多冗余并能降低算法识别的性能。目前也提出了很多种监督的 LPP, 但是它们也都只考虑了同类数据的局部性, 没有考虑不同类数据之间信息。本文基于以上这些问题, 提出了一种基于无关性判别保局的特征提取算法。该算法在保持同类信息局部性的同时, 扩大了不同类之间的距离, 因此在诸如指纹识别、步态识别等模式分类领域中, 比经典算法 PCA、

LDA 和 LPP 能更有效地提取特征信息, 为下一步的分类做出了较好的贡献。

1 LPP、DLPP 和 UDLPP 算法

下面对保局算法 LPP 及其改进的 DLPP 和 UDLPP 算法进行简单介绍。

1.1 LPP 算法

LPP 目标是保持数据之间的相似性, 即原始空间上相邻的数据点在投影空间上也保持相应的邻近关系。假定数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 含有 n 个样本点, 每个样本点 $\mathbf{x}_i$ 属于 D 维欧氏空间, 即 $\mathbf{x}_i \in \mathbf{R}^D$, 且样本数据来自一本征维数为 d ($d \ll D$) 的非线性流形。对于原始空间中的一数据点 $\mathbf{x}$, 寻找一投影 $\mathbf{W}$, 使得 $\mathbf{y} = \mathbf{W}^T \mathbf{x}$, 通过求解以下最小化问题得到最佳的投影:

$$\begin{aligned} \mathbf{W}_{\text{opt}} &= \arg \min_{\mathbf{W}} \sum_{ij} (\mathbf{y}_i - \mathbf{y}_j)^2 S_{ij} = \\ &\arg \min_{\mathbf{W}} \sum_{ij} (\mathbf{W}^T \mathbf{x}_i - \mathbf{W}^T \mathbf{x}_j)^2 S_{ij} = \\ &\arg \min_{\mathbf{W}} \mathbf{W}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} \end{aligned} \quad (1)$$

式中, S_{ij} 刻画了两数据 $\mathbf{x}_i, \mathbf{x}_j$ 之间的相似性:

$$S_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/t) & \mathbf{x}_i, \mathbf{x}_j \text{ 为 } k \text{ 邻近点} \\ 0 & \text{其他} \end{cases}$$

附加约束条件 $\mathbf{W}^T \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{W} = 1$, 拉普拉斯算子 $\mathbf{L} = \mathbf{D} - \mathbf{S}$, $\mathbf{D}$ 为对角矩阵, 其元素为对称矩阵 $\mathbf{S}$ 的列向量 (或行向量) 元素之和, 即 $D_{ij} = \sum_j S_{ij}$ 。最后可以通过以下广义特征方程求解:

$$\mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{W} = \lambda \mathbf{X} \mathbf{D} \mathbf{X}^T \mathbf{W} \quad (2)$$

假定 $w_0, w_1, \dots, w_{d-1}$ 为特征方程 (2) 的最小 d 个解, 它们所对应的特征值分别为 $\lambda_0, \lambda_1, \dots, \lambda_{d-1}$ 且 $\lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_{d-1}$, 那么可以得到如下映射: $\mathbf{x}_i \rightarrow \mathbf{y}_i = \mathbf{W}^T \mathbf{x}_i$ 。其中 $\mathbf{y}_i$ 为 d 维向量, $\mathbf{W}$ 为变换矩阵。

1.2 DLPP 算法及其 UDLPP 算法

由上一小节可以看出, LPP 是一种非监督学习算法, 即算法未考虑样本的类别信息。为此, Yu 等人提出了 DLPP^[14] (discriminant locality preserving projections)。DLPP 虽然考虑了样本的类别信息, 但它提取的特征向量存在一些冗余, 针对这个问题, Yu 和 Wang 提出了 UDLPP^[15] (uncorrelated discriminant locality preserving projection)。

DLPP 的目标函数是:

$$\min \sum_{c=1}^C \sum_{j=1}^{n_c} (y_i^c - y_j^c) W_{ij}^c / \sum_{i,j=1}^C (m_i - m_j)^2 B_{ij} \quad (3)$$

式中, C 为样本的类别数, n_c 为第 c 类样本的数目, y_i^c 是第 c 类中的第 i 个样本经过投影后所得到的向量。 m_c 为投影后向量的均值, 即 $m_c = \frac{1}{n_c} \sum_{i=1}^{n_c} y_i^c$ 。 W_{ij} 为样本的类内权值, B_{ij} 为样本的类间权值。

类似 LPP, 假定投影是线性的, 即 $y = a^T x$, 经过推导, 分子和分母可以简化为

$$\frac{1}{2} \sum_{c=1}^C \sum_{j=1}^{n_c} (y_i^c - y_j^c) W_{ij}^c = a^T X L X^T a \quad (4)$$

$$\frac{1}{2} \sum_{i,j=1}^C (m_i - m_j)^2 B_{ij} = a^T F H F^T a \quad (5)$$

$$W_{ij}^c = \exp(-\|x_i^c - x_j^c\|^2/t) \quad (6)$$

$$B_{ij} = \exp(-\|f_i - f_j\|^2/t) \quad (7)$$

式中, f_i 为初始样本第 i 类的均值, 即 $f_i = \frac{1}{n_i} \sum_{k=1}^{n_i} x_k^i$ 。

$H = M - B$, 而 $E_{ii} = \sum_j B_{ij}$ 。最后, DLPP 的目标函数为

$$a = \operatorname{argmin} \frac{a^T X L X^T a}{a^T F H F^T a} \quad (8)$$

从 DLPP 的目标函数可以看出, 算法不仅考虑了样本的局部性, 而且投影后, 使得不同类的距离变大, 因此比 LPP 更有利于分类。为了消除所得向量之间的冗余, 研究者提出了 UDLPP 算法, 它的目标函数是

$$\min_{V^T S_i V = I} \frac{\operatorname{tr}(V^T X L X^T V)}{\operatorname{tr}(V^T X B X^T V)} \quad (9)$$

式中, $B = G - W$, 而 $G = I - (1/n) e e^T$, e 为元素都为 1 的 n 维单位列向量, $W = I - E$, I 为单位矩阵, E_{ij} 的定义为

$$E_{ij} = \begin{cases} 1/n_c & x_i \text{ 和 } x_j \text{ 属于类 } c \\ 0 & \text{其他} \end{cases} \quad (10)$$

UDLPP 虽然保持了样本的局部性, 也使得投影后不同类在一定程度上起到了分离作用, 但是它并未考虑样本的分布情况, 即它把同一类样本的权值都设置为一样, 事实上, 将权值根据样本的分布进行设置更有利于分类。

2 无关性判别保局算法

提出一种无关性判别保局特征提取算法, 与

LPP 的最大不同在于该算法考虑了类别信息和类间信息, 并使得投影后样本区分度更高, 同时提取的特征之间相互无关。与 UDLPP 的最大区别就是, 该算法在考虑样本信息的时候, 充分利用了样本的分布信息, 即考虑了样本的空间信息。具体来讲就是: 通过一种新的权值方法, 将那些可能远离自己所属的类别而靠近其他类别的样本进行了某种程度上的分离。

定理 1 UDLPP 中同一类任何两样本的权值为一常数。

证明 从 UDLPP 的类间散度矩阵定义可以看出

$$B = G - W = \left(I - \frac{1}{n} e e^T \right) - (I - E) = E - \frac{1}{n} e e^T \quad (11)$$

因此可以看出 B_{ij} 只与 n_c 有关, 即 UDLPP 将同一类的样本权值设置为一常数, 证毕。

但由于受光照、视点、姿态和表情的影响, 有些样本可能远离自己所属的类别而靠近其他类别的样本, 这类样本对于分类不利, 应削弱其在特征提取时所起的作用。

2.1 UDLPP 简介

设有样本集 $X = \{x_1, x_2, \dots, x_n\}$, 共有 C 类, 第 c 类的样本个数为 n_c , 显然有 $\sum_{c=1}^C n_c = n$ 。UDLP 算法在保持数据的局部结构的同时, 考虑类间间距, 并且在它们之间进行折中。因此目标函数可以表示为

$$\min \alpha \sum_{i=1}^n \sum_{j \in N(i)} (y_i - y_j)^2 W_{ij} + (1 - \alpha) \sum_{i=1}^n \sum_{j \notin N(i)} (y_i - y_j)^2 W'_{ij} \quad (12)$$

式中, $\alpha \in [0, 1]$ 是一参数, 在保局程度和类内间距间进行调整, 因为像人脸这种复杂的物体, 有研究表明它存在于一个非线性的流形子空间中, 因此算法必须保证保持人脸的流形结构, 即人脸的局部性, 同时还需尽可能的扩大不同类之间的距离。算法在局部性和类间距离进行调整, 现将参数 α 的范围设成 $[0, 1]$; $N(i)$ 是数据点 x_i 的 k 最近邻近领域, W_{ij} 是类内局部权值, W'_{ij} 是类间权值。

$$W_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2/t) & x_i \text{ 和 } x_j \text{ 来自同一类} \\ 0 & x_i \text{ 和 } x_j \text{ 来自不同类} \end{cases} \quad (13)$$

$$W'_{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/t)(1 - & \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 来自不同类} \\ \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/t)) & \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 来自同一类} \\ 0 & \end{cases} \quad (14)$$

令

$$J_1 = \sum_{i=1}^n \sum_{j \in N(i)} (\mathbf{y}_i - \mathbf{y}_j)^2 W_{ij} \quad (15)$$

$$J_2 = \sum_{i=1}^n \sum_{j \notin N(i)} (\mathbf{y}_i - \mathbf{y}_j)^2 W'_{ij} \quad (16)$$

由权值公式可以看出, 如果两数据 $\mathbf{x}_i, \mathbf{x}_j$ 来自同一类, 并且距离较近, 则说明它们之间的权值比较大 (即较相似), 由目标函数的前半部分 J_1 可以看出, 投影后保持了这种相似性。如果两数据来自不同类, 并且距离较近, 则由目标函数的后半部分 J_2 可以看出, 它们之间的权值 (即相似性) 比同等条件下 LPP 的相似性要小, 因此起到将来自不同类, 距离较近的样本进行分离的作用, 这样明显有利于样本分类。直观地说, 算法可以将那些可能远离自己所属的类别而靠近其他类别的样本在某种程度上的进行了分离。

以下对它们进行简化:

$$\begin{aligned} J_1 &= \sum_{i=1}^n \sum_{j \in N(i)} (\mathbf{y}_i - \mathbf{y}_j)^2 W_{ij} = \\ &= \sum_{i=1}^n \sum_{j \in N(i)} (\mathbf{A}\mathbf{x}_i - \mathbf{A}\mathbf{x}_j)^2 W_{ij} = \\ &= 2\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{A}) \end{aligned} \quad (17)$$

式中, $\mathbf{L} = \mathbf{D} - \mathbf{W}$, 定义与 LPP 相同。

$$\begin{aligned} J_2 &= \sum_{i=1}^n \sum_{j \notin N(i)} (\mathbf{y}_i - \mathbf{y}_j)^2 W'_{ij} = \\ &= \sum_{i=1}^n \sum_{j \notin N(i)} (\mathbf{A}\mathbf{x}_i - \mathbf{A}\mathbf{x}_j)^2 W'_{ij} = \\ &= 2\text{tr}(\mathbf{A}^T \mathbf{X} \mathbf{L}' \mathbf{X}^T \mathbf{A}) \end{aligned} \quad (18)$$

式中, $\mathbf{L}' = \mathbf{D}' - \mathbf{W}'$, $D'_{ii} = \sum_{j=1}^n W'_{ij}$ 。

外加无关性限制条件:

$$\begin{aligned} E[(\mathbf{y}_i - E(\mathbf{y}_i))(\mathbf{y}_j - E(\mathbf{y}_j))] &= \\ \mathbf{a}_i \mathbf{S}_i \mathbf{a}_j &= 0 \quad (i \neq j) \end{aligned} \quad (19)$$

为方便计算, 可以把 $\mathbf{a}_i$ 归一化, 即

$$\mathbf{a}_i^T \mathbf{S}_i \mathbf{a}_i = 1 \quad (20)$$

这时 $\mathbf{A}^T \mathbf{S}_i \mathbf{A} = \mathbf{I}$ 。其中 $\mathbf{S}_i$ 的定义同 LDA。

即 $\mathbf{S}_i = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T$, $\boldsymbol{\mu} = \sum_{i=1}^n \mathbf{x}_i$ 。

所以问题归结为

$$\begin{cases} \min \frac{1}{2}(\alpha J_1 + (1 - \alpha) J_2) = \\ \text{tr}(\mathbf{A}^T \mathbf{X}(\alpha \mathbf{L} + (1 - \alpha) \mathbf{L}') \mathbf{X}^T \mathbf{A}) \\ \text{s. t. } \mathbf{A}^T \mathbf{S}_i \mathbf{A} = \mathbf{I} \end{cases} \quad (21)$$

该问题可由 Lagrange 乘子法来解决, 令

$$\begin{aligned} L(\mathbf{A}, \lambda) &= \mathbf{A}^T \mathbf{X}(\alpha \mathbf{L} + (1 - \alpha) \mathbf{L}') \mathbf{X}^T \mathbf{A} - \\ &\quad \lambda(\mathbf{A}^T \mathbf{S}_i \mathbf{A} - \mathbf{I}) \end{aligned} \quad (22)$$

对 $\mathbf{A}$ 进行求偏导, 得到:

$$\frac{\partial L(\lambda)}{\partial \mathbf{A}} = \mathbf{X}(\alpha \mathbf{L} + (1 - \alpha) \mathbf{L}') \mathbf{X}^T \mathbf{A} - \lambda \mathbf{S}_i \mathbf{A}$$

令 $\frac{\partial L(\lambda)}{\partial \mathbf{A}} = 0$, 则得到以下广义特征值问题。

$$\mathbf{X}(\alpha \mathbf{L} + (1 - \alpha) \mathbf{L}') \mathbf{X}^T \mathbf{A} = \lambda \mathbf{S}_i \mathbf{A} \quad (23)$$

假设特征方程的最小 d 个特征值为 $\lambda_1, \lambda_1, \dots, \lambda_d$, 其中 $\lambda_1 \leq \lambda_1 \leq \dots \leq \lambda_d$, $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d$ 是它们所对应的特征向量, 令 $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_d]$, 则 $\mathbf{x} \rightarrow \mathbf{y}$ 的嵌入为

$$\mathbf{x} \rightarrow \mathbf{y} = \mathbf{A}^T \mathbf{x} \quad (24)$$

这样就完成了特征提取过程, 接下去需要设计分类器。

2.2 分类器设计

采用常用的最近邻 (nearest neighbor) 分类器。设两个特征向量为 $\mathbf{y}_i = [y_1^i, y_2^i, \dots, y_d^i]$, $\mathbf{y}_j = [y_1^j, y_2^j, \dots, y_d^j]$ 。

两者之间的距离定义为

$$\text{dist}(\mathbf{y}_i, \mathbf{y}_j) = \sqrt{\sum_{k=1}^d (y_k^i - y_k^j)^2} \quad (25)$$

设训练样本的特征向量为 $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n$ 每一个样本都属于一个类别 C_k , 测试样本的特征向量为 $\mathbf{y}_{\text{test}}$, 如果 $\text{dist}(\mathbf{y}_{\text{test}}, \mathbf{y}_k) = \min_j d(\mathbf{y}_{\text{test}}, \mathbf{y}_j)$, $j = 1, 2, \dots, n$, $\mathbf{y}_k \in C_k$, 则测试样本 $\mathbf{y}_{\text{test}} \in C_k$ 。

3 实验结果及其分析

为验证算法的正确性和有效性, 将该算法在 ORL 和 Yale 标准人脸库上进行实验。ORL 人脸库有 40 个人, 每人 10 张图片, 一共 400 张, 图像是在不同时期, 不同光线强度下拍摄的, 其中包括姿态、光照和表情的变化。图 1 是取自 ORL 人脸库的第一个人的样本。Yale 人脸库有 15 人, 每人 11 张图

片,一共 165 张,也受表情、光照等因素的变化。图 2 是来自 Yale 人脸库第 1 个人的样本。



图 1 ORL 人脸图像的样本
Fig.1 Samples from ORL



图 2 Yale 人脸图像的样本
Fig.2 Samples from Yale

为了有效地计算,所有图像都缩放成 32×32 像素,即每一图像可以看成是 $D = 32 \times 32 = 1024$ 维向量。每人分别随机选择 3、4、5、6、7 幅图像用作训练样本,其他图像用于测试样本,重复 20 次,最后取平均值作为识别结果,采用 2.2 节给出的最邻近分类器进行分类。由 2.1 节的介绍可知,具体实施的时候需要确定参数 α ,如何确定 α 是一个需要解决的问题,目前还没有具体的解决办法,这里不妨设置 $\alpha = 0.5$,UDLP 与算法 PCA、LDA、LPP、D-LPP 和 UDLP 进行了比较,实验结果如表 1、表 2 所示。

表 1 算法在 ORL 人脸库中的识别结果/%

Tab.1 Recognition rate on ORL						
训练样本数	PCA	LDA	LPP	D-LPP	UDLPP	UDLP
3	78.2	84.7	82.1	90.6	85.3	88.4
4	83.7	90.8	87.6	95.4	93.6	94.7
5	86.8	93.7	89.8	96.8	95.7	95.6
6	89.1	95.6	93.3	98.4	96.7	98.2
7	92.4	96.9	94.1	99.3	97.3	99.3

表 2 算法在 Yale 人脸库中的识别结果/%

Tab.2 Recognition rate on Yale						
训练样本数	PCA	LDA	LPP	D-LPP	UDLPP	UDLP
3	70.9	72.9	73.1	84.6	82.8	83.1
4	73.4	74.5	75.6	86.2	84.1	85.4
5	73.9	75.9	76.2	87.8	84.6	86.7
6	75.3	76.2	78.5	89.4	87.3	88.2
7	76.8	78.1	79.7	92.5	89.4	90.3

从实验结果可以看出,各类算法在 ORL 人脸库中的结果比较理想,这是因为人脸的表情、光照等因素变化较少,适合提取关键特征。从实验数据上可以看出,LDA 的识别效果优于 PCA,这是因为 PCA 只是较好地在低维空间中展现了原数据,LDA 考虑了类内信息和类间信息,使得投影后数据的区分度提高了。LPP 算法的识别率高于 PCA 和 LDA,这是因为 PCA 和 LDA 都假设人脸存在于欧氏空间中,而人脸空间更可能存在于非线性流形子空间中,LPP 考虑了人脸的局部信息,在一定程度上能解决这类问题。UDLP 不仅保持了数据的局部性,同时也考虑了类别信息,使得投影后的数据之间的类间区分度加强了。与传统 LPP 不同,D-LPP 不需要解决矩阵的奇异值问题,不需要进行 PCA 投影,因此没有损失信息,效果比较理想。由实验结果可以看出,与 D-LPP 效果相比,UDLP 还有差异,因此将 UDLP 扩展为 2 维算法是我们将来的一个研究方面。从算法中也可以看出,在计算数据点之间的权值时避免了像 LPP 那样需要设置一参数 k (k 邻近图),而这个 k 值的设定是比较难的,一般都是通过经验或者交叉验证法求得,没有理论依据。与 UDLP 相比,UDLP 充分考虑了样本的分布信息,在权值计算上更为合理,因此识别效果优于 UDLP。求得后的特征向量是两两相互无关的,这样减少了数据之间的冗余,对分类问题起到了促进作用,因此总体识别效果较理想。

4 结 论

本文提出了一种新的特征提取算法,即基于无关性判别保局的特征提取算法,并将其应用于人脸识别。算法一方面保留了 LPP 算法的局部保持特性,另一方面克服了 LPP 没有考虑类别信息而对分类效果不理想这一特点,加强了类间区分度,因此具有较好的识别效果。实验证实了 UDLP 比 PCA、

LDA、LPP 和 UDLPP 有更好的识别性能。如何确定 α ,使得算法的性能达到最优是今后的一个研究方向。

参考文献 (References)

- [1] Zhao W, Chellappa R, Phillips P J, et al. Face recognition: a literature survey [J]. ACM Computing Survey, 2003, 12: 399-458.
- [2] Turk M, Pentland A. Eigenfaces for recognition [J]. Cognitive Neurosci, 1991, 3 (1): 71-86.
- [3] Belhumeur P N, Kriegman D J. Eigenfaces vs fisherfaces: recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19: 711-720.
- [4] He X, Niyogi P, Han J. Face recognition using laplacianfaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(3): 328-340.
- [5] Jolliffe I T. Principal Component Analysis, Series: Springer Series in Statistics[M]. 2nd ed, NY:Springer, 2002: 487-492.
- [6] Duda R, Hart P. Pattern Classification and Scene Analysis[M]. New York: Wiley Press, 1973: 114-117.
- [7] He X F, Niyogi P. Locality preserving projections [C]// Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2004: 327-334.
- [8] Tenenbaum J B, Silva V de, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5500): 2319-2323.
- [9] Rowies S, Saul L. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.
- [10] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396.
- [11] 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, 2008, 30(3): 539-541. [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.]
- [12] Chen Jiangfeng, Li Bo, Yuan Baozong. Face recognition using direct LPP algorithm [C]// Proceedings of the 9th International Conference on Signal Processing Proceedings. Washington, DC, USA: The IEEE Computer Society, 2008: 1457-1460.
- [13] Cai D, He X F, Han J W. Orthogonal Laplacianfaces for Face Recognition[J]. IEEE Transactions on Image Processing, 2006, 15: 3608-3614.
- [14] Yu Weiwei, Teng Xiaolong, Liu Chongqing. Discriminant locality preserving projections: A new method to face representation and recognition[C]// Proceedings 2nd Joint IEEE international Workshop on VS-PETS. Washington, DC, USA: The IEEE Computer Society, 2005: 201-207.
- [15] Yu X, Wang X. Uncorrelated discriminant locality preserving projections[J]. Signal Processing Letters, 2008, 15: 361-364.