

改进双向二维局部保持投影的人脸识别算法

吴 斌, 王利龙*, 邵延华

(西南科技大学信息工程学院 四川 绵阳 621010)

【摘要】为更好地处理图像小样本问题,且克服二维局部保持投影(2DLPP)算法只能保持数据局部性质的缺陷,通过结合二维主成分分析(2DPCA)和二维线性鉴别分析(2DLDA)的算法特性,提出了一种改进的双向二维局部保持投影的人脸识别算法。首先,引入样本类别信息改进权重矩阵,增强2DLPP算法对样本变化的鲁棒性;其次,提出改进2DLPP+2DPCA、2DLPP+2DLDA两种融合算法并分别用于输入样本图像数据的行、列方向特征提取。在特征选择后得到行、列方向上的最优投影;最后,通过对样本数据进行行、列方向投影,利用最近邻分类器对样本数据进行分类并获得在给定数据集上的识别结果。在人脸数据集ORL、YALE和AR上的实验结果表明,该算法在人脸识别性能上总体优于2DPCA、2DLDA、2DLPP、(2D)²PCA、(2D)²LDA、(2D)²PCALDA和(2D)²LPP-PCA等算法。

关键词 人脸识别; 特征提取; 二维线性鉴别分析; 二维局部保持投影; 二维主成分分析
中图分类号 TP391.4 文献标志码 A doi:10.3969/j.issn.1001-0548.2019.06.015

Face Recognition Algorithm Based on Improved Bi-directional Two Dimensional Locality Preserving Projection

WU Bin, WANG Li-long*, and SHAO Yan-hua

(Information Engineering School, Southwest University of Science and Technology Mianyang Sichuan 621010)

Abstract In order to better deal with the problem of small sample size, and to overcome the defect of two-dimensional locality preserving projection (2DLPP) algorithm which can only keep the local nature of the data, an improved bi-directional two dimensional locality preserving projection algorithm for face recognition is proposed, by combining the characteristics of Two-Dimensional Principal Component Analysis (2DPCA) and Two-Dimensional Linear Discriminate Analysis (2DLDA). First, it introduced the sample class information to improve the weight matrix, and enhances the robustness of the 2DLPP algorithm to samples' changes. Second, two fusion algorithms of 2DLPP+2DPCA and 2DLPP+2DLDA were improved to the feature extraction of row and column direction of the input sample image data. After the feature selection, the optimal projection in row and column direction was obtained. Finally, by performing row and column direction projection on the sample data, the nearest neighbor classification was used to classify the sample data and obtain the recognition results on the given datasets. Experimental results on the face datasets ORL, YALE and AR show that the proposed algorithm is generally superior to the algorithms such as 2DPCA, 2DLDA, 2DLPP, (2D)²PCA, (2D)²LDA, (2D)²PCALDA, and (2D)²LPP-PCA in face recognition performance.

Key words face recognition; feature extraction; two-dimensional linear discriminate analysis (2DLDA); two-dimensional locality preserving projection(2DLPP); two-dimensional principal component analysis(2DPCA)

得益于当前机器视觉与模式识别等领域的普遍研究,人脸识别算法^[1]得到了更为广泛的改进与应用,其中以最能表征人脸特征的流形学习算法尤为突出。

传统基于子空间的流形学习算法^[2-4]将图像矩阵降维到一维向量的过程会破坏样本数据结构,并可能丢失部分有用信息。文献[5]提出二维主成分分

析算法(2DPCA),利用原始图像构建协方差矩阵来获取特征向量,保留了图像数据全局信息。文献[6]提出二维线性鉴别分析算法(2DLDA),能克服矩阵自身隐式奇异问题,选择使得Fisher判别准则函数达到极值的向量作为样本数据点的最佳投影方向,并将样本投影到该方向得到最大类间散度和最小类内散度,具有较高的鉴别能力,但需大量的特征矩阵。

收稿日期: 2018-09-26; 修回日期: 2019-03-12

基金项目: 国家自然科学基金(61601382); 四川省教育厅项目(17ZB0454)

作者简介: 吴斌(1965-),男,教授,主要从事智能控制、图像处理及其应用等方面的研究。

通信作者: 王利龙, Email: 2205877852@qq.com

文献[7]提出二维局部保持投影算法(2DLPP), 利用局部保持准则从图像矩阵中提取特征, 但欠缺对样本数据全局特征和鉴别信息的考虑, 会对图像因素(如遮挡、光照等)的变化较为敏感。

单一算法仅侧重提取图像的部分信息而无法达到较高的识别准确率。为此, 融合算法^[8-14]相继被提出, 如文献[8]提出改进算法, 利用2DPCA保留图像空间信息的特点, 融合2DLDA避免小样本尺寸问题的特点, 不需要进一步约简特征矩阵的维数, 同时提升了分类的准确率。文献[9]提出了(2D)² PCA算法, 同时考虑图像行、列方向特征, 表现出了更高的识别率。融合算法在提取到更多特征信息的同时增大了计算复杂度和内存消耗。为进一步优化算法性能, 文献[13]提出了一种结合2DLPP与2DPCA的人脸识别方法, 对人脸图像同时进行2DLPP和2DPCA投影, 减少保存人脸特征数据的内存占用, 并能有效的提取人脸局部和全局特征。

为进一步提高算法的稳定性, 本文提出了改进双向二维局部保持投影算法。首先, 引入改进权重矩阵来优化2DLPP算法; 其次, 对图像数据采用行

方向改进2DLPP+2DPCA投影, 保留图像数据的整体空间信息和分类信息; 同时, 列方向采用2DLPP+2DLDA投影, 引入类内、类间鉴别信息增强算法分类性能; 最后利用最近邻分类器进行分类。

1 改进2DLPP算法

在人脸姿态、遮挡变化不大的情况下, 2DLPP^[7]通过对二维图像矩阵进行处理, 能很好地保留图像局部结构, 但仍受自身无监督局限, 为此, 本文提出改进算法, 具体流程如下:

1) 构造近邻图: 假设人脸样本集 \mathbf{X} 有 M 张人脸图像, 构造包含 M 个节点的有向图, 采用 K 近邻准则确定图像间近邻关系;

2) 选择权重: 假设训练样本集有 C 类, 第 i 类有 m_i 个训练样本, 训练样本总数为 $M = \sum_{i=1}^c m_i$, $i=1, 2, \dots, C$ 。给定训练样本数据集 $\{x_i\}_{i=1}^M$, $x_i \in \mathbf{R}^{m \times n}$, m, n 分别对应样本图像的宽和高, 则有改进权重矩阵 $\mathbf{S} = [S_{i,j}]$:

$$S_{i,j} = \begin{cases} \frac{1}{l_{\text{intra}}} \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right) \left(1 + \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right)\right) & \text{如果 } x_i \text{ 属于 } x_j \text{ 的 } k \text{ 个类内最近邻} \\ \frac{1}{l_{\text{inter}}} \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right) \left(1 - \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right)\right) & \text{如果 } x_i \text{ 属于 } x_j \text{ 的 } k \text{ 个类间最近邻} \\ 0 & \text{如果 } x_i \text{ 不属于 } x_j \text{ 最近邻} \end{cases} \quad (1)$$

式中, $\|\cdot\|$ 为欧氏距离; $\frac{1}{l_{\text{intra}}}$ 为样本类内权重修正因子;

$\frac{1}{l_{\text{inter}}}$ 为样本类间权重修正因子。因训练样本集

中同类样本个数要远少于不同类样本数, 故取 l_{intra} 为样本图像训练数, 即 $l_{\text{intra}} = M_{\text{tr}} C$, M_{tr} 为训练样本集中选取的每一类图像训练个数。取 l_{inter} 为样本集中所有满足类间最近邻关系的不同类图像样本总数, 取不同类样本间相似度大于平均相似度的样本,

并统计总个数。由 $1 \leq 1 + \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right) \leq 2$, 且

$0 \leq 1 - \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right) \leq 1$, 故而类间和类内鉴别

信息得到了很好的监督, 此外, 依据样本集特性, 始终满足 $0 < l_{\text{intra}} \leq l_{\text{inter}} < 1$, 改进后的类间权重较原算法权重要小的多, 而类内权重无太大变化。

3) 特征映射: 令 $\mathbf{A} \in \mathbf{R}^{n \times q}$ 为标准列正交矩阵, 且 $n \geq q$, q 对应于不同列向量维数。

将训练样本集 \mathbf{X} 投影到 \mathbf{A} 上, 有投影后矩阵 $\mathbf{y}_i = x_i \mathbf{A}$, $\mathbf{y}_i \in \mathbf{R}^{m \times q}$, $i=1, 2, \dots, M$ 。经权重优化, 改进2DLPP目标函数为:

$$\min_{\mathbf{A}} \sum_{i,j} S_{i,j} \|\mathbf{y}_i - \mathbf{y}_j\|^2 = \min_{\mathbf{A}} \sum_{i,j} S_{i,j} \|x_i \mathbf{A} - x_j \mathbf{A}\|^2 = \min_{\mathbf{A}} \mathbf{A}^T \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} \quad (2)$$

约束条件为:

$$\mathbf{A}^T \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} = 1 \quad (3)$$

式中, \mathbf{D} 为对角矩阵; \mathbf{L} 表示Laplacian矩阵; \otimes 为Kronecker积; \mathbf{I}_m 为 $m \times m$ 的单位矩阵。联立两式可得:

$$\mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} = \lambda \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} \quad (4)$$

根据广义特征值求解, 选取 q 个最大广义特征值所对应的广义特征向量, 得到改进2DLPP算法的

最优特征矩阵 $\mathbf{A}_{\text{opt}} = [a_1, a_2, \dots, a_q]$ 。

2 改进双向二维局部保持投影

虽然改进2DLPP算法有监督的注重图像样本间的类别信息,但算法没有充分考虑到图像的全局特征和鉴别属性。为完备提取图像特征,本文借鉴前期的融合算法工作^[8-14]将不同组合算法分别实现行、列方向特征映射最后得到降维特征图的算法思想,提出改进融合算法克服数据集的小样本问题,保证改进算法的有效性。

改进融合算法的整体设计思路如下:首先对图像集进行行方向投影,采用改进2DLPP+2DPCA算法计算得到最优投影矩阵 \mathbf{A}_{opt} ,用 \mathbf{A}_{opt} 对训练样本集 \mathbf{X} 进行投影得到 $m \times q$ 维特征矩阵 $\mathbf{Y} = \mathbf{X}\mathbf{A}_{\text{opt}}$;然后对样本集 \mathbf{X} 进行列方向投影,采用改进的2DLPP+2DLDA方法计算得到相应的最优投影矩阵 \mathbf{Z}_{opt} ,并用 \mathbf{Z}_{opt} 对图像矩阵 \mathbf{Y} 进行投影得到新的训练样本特征矩阵 $\mathbf{C}_{\text{tr}} = \mathbf{Z}_{\text{opt}}^T \mathbf{X}\mathbf{A}_{\text{opt}}$ 。

2.1 行方向特征提取

2DPCA算法虽然能对图像整体降维来保留数据全局特征,但丢失了更多的局部结构信息。根据人脸最显著特征(如眼睛、眉毛和嘴)主要集中在水平方向,可知行方向特征提取能极大保留人脸特征。为保证图像局部结构属性并兼顾全局特征,提出改进2DLPP+2DPCA融合算法对人脸图像进行行方向特征提取,首先采用改进权重矩阵的2DLPP算法,将训练样本集 \mathbf{X} 投影到 \mathbf{A} 上得投影后矩阵 \mathbf{Y}^1 。同时采用2DPCA算法将样本集 \mathbf{X} 投影到 \mathbf{A} 上,得到图像的协方差矩阵:

$$\mathbf{G} = \mathbf{E}[(\mathbf{X} - \mathbf{E}\mathbf{X})^T(\mathbf{X} - \mathbf{E}\mathbf{X})] = \frac{1}{M} \sum_{i=1}^M (x_i - \bar{x})^T (x_i - \bar{x}) \quad (5)$$

式中, $\bar{x} = \frac{1}{M} \sum_{i=1}^M x_i$ 。投影样本总散度矩阵为:

$$\mathbf{J}(\mathbf{A}) = \text{tr}\{\mathbf{E}[\mathbf{Y}^1 - \mathbf{E}\mathbf{Y}^1][\mathbf{Y}^1 - \mathbf{E}\mathbf{Y}^1]^T\} = \text{tr}\{\mathbf{E}[\mathbf{X}\mathbf{A} - \mathbf{E}\mathbf{X}\mathbf{A}][\mathbf{X}\mathbf{A} - \mathbf{E}\mathbf{X}\mathbf{A}]^T\} = \mathbf{A}^T \mathbf{G} \mathbf{A} \quad (6)$$

则其目标函数为 $F(\mathbf{A}) = \max_{\mathbf{A}} \mathbf{A}^T \mathbf{G} \mathbf{A}$ 。

联立改进2DLPP算法,可得到:

$$\begin{cases} \max_{\mathbf{A}} \mathbf{A}^T \mathbf{G} \mathbf{A} \\ \min_{\mathbf{A}} \mathbf{A}^T \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} \\ \text{s.t. } \mathbf{A}^T \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} = 1 \end{cases} \quad (7)$$

式中, \otimes 为Kronecker积; \mathbf{D} 为对角矩阵:

$$\mathbf{D}_{i,i} = \sum_j \mathbf{S}_{i,j}, \mathbf{L} = \mathbf{D} - \mathbf{S} \quad (8)$$

考虑到算法一般性,可将上式进一步化简:

$$\begin{cases} \max_{\mathbf{A}} (\mathbf{A}^T \mathbf{G} \mathbf{A} - \mathbf{A}^T \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A}) \\ \text{s.t. } \mathbf{A}^T \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} = 1 \end{cases} \quad (9)$$

根据广义特征值求解式:

$$(\mathbf{A}^T \mathbf{G} \mathbf{A} - \mathbf{A}^T \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A}) = \lambda \mathbf{A}^T \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_m) \mathbf{X} \mathbf{A} \quad (10)$$

得最优投影矩阵 $\mathbf{A}_{\text{opt}} = [a_1, a_2, \dots, a_q]$ 。

2.2 列方向特征提取

为进一步增强样本间的鉴别属性,采用改进2DLPP+2DLDA融合算法进行列方向特征提取,2DLDA算法获取图像数据的矩阵集标识来规避奇异问题。令 $\mathbf{Z} \in \mathbb{R}^{m \times p}$ 为标准列正交矩阵,且 $m \geq p$,首先采用改进2DLPP将训练样本集 \mathbf{X} 投影到 \mathbf{Z} 上,根据式(2)、式(3)可得改进2DLPP的目标函数为:

$$\min_{\mathbf{Z}} \mathbf{Z} \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_n) \mathbf{X} \mathbf{Z}^T, \text{ 且 } \mathbf{Z} \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_n) \mathbf{X} \mathbf{Z}^T = 1$$

式中, \mathbf{L} 可通过式(8)得到; \mathbf{I}_n 为 $n \times n$ 的单位矩阵。采用2DLDA将 \mathbf{X} 投影到 \mathbf{Z} 上,可以求解得到投影样本的类间散度矩阵 \mathbf{S}_B 和类内散度矩阵 \mathbf{S}_W ,得目标函数 $F(\mathbf{Z})$ 为:

$$F(\mathbf{Z}) = \max_{\mathbf{Z}} \frac{\text{tr}(\mathbf{S}_B)}{\text{tr}(\mathbf{S}_W)} = \max_{\mathbf{Z}} \mathbf{Z} \mathbf{G}_W^{-1} \mathbf{G}_B \mathbf{Z}^T \quad (11)$$

再联合改进2DLPP算法,得

$$\begin{cases} \max_{\mathbf{Z}} (\mathbf{Z} \mathbf{G}_W^{-1} \mathbf{G}_B \mathbf{Z}^T - \mathbf{Z} \mathbf{X}^T (\mathbf{L} \otimes \mathbf{I}_n) \mathbf{X} \mathbf{Z}^T) \\ \text{s.t. } \mathbf{Z} \mathbf{X}^T (\mathbf{D} \otimes \mathbf{I}_n) \mathbf{X} \mathbf{Z}^T = 1 \end{cases} \quad (12)$$

求解 p 个广义特征值可得到列最优投影矩阵 $\mathbf{Z}_{\text{opt}} = [z_1, z_2, \dots, z_p]$ 。结合2.1节得到训练样本集特征投影矩阵 $\mathbf{C}_{\text{tr}} = \mathbf{Z}_{\text{opt}}^T \mathbf{X}\mathbf{A}_{\text{opt}}$ 。

2.3 分类

通过改进融合算法得到训练样本集在投影空间上的特征矩阵,同理,选取测试样本集 \mathbf{X}' 得到的特征矩阵 $\mathbf{C}_{\text{te}} = \mathbf{Z}_{\text{opt}}^T \mathbf{X}'\mathbf{A}_{\text{opt}}$ 。根据最近邻分类器,可得到训练样本集 \mathbf{X} 和测试样本集 \mathbf{X}' 之间的欧式距离:

$$d_{c_{\text{tr}}, c_{\text{te}}} = \sqrt{\sum_{i=1}^p \sum_{j=1}^q (C_{\text{tr}}^{i,j} - C_{\text{te}}^{i,j})^2} \quad (13)$$

将该欧氏距离进行分类并用于识别。

3 实验结果与分析

本节主要针对算法性能,将改进算法与2DPCA、2DLDA、2DLPP、(2D)²PCA、(2D)²LDA、(2D)²PCALDA

和(2D)²LPP-PCA这几种算法在人脸数据集ORL、YALE和AR上进行对比。各算法均在Matlab R2017a平台下实现。

3.1 验证数据集

ORL人脸数据集包含40个类, 每类均有10张人脸图像, 且面部表情(睁眼或闭眼、微笑或不微笑)与面部细节(戴眼镜或不戴)均不同, 部分图像在不同

的时间采集, 所有灰度图大小为92×112个像素点。
YALE库中包含15个人的165张照片, 每类照片均采自不同的光照和表情条件, 大小为100×100个像素点。AR人脸数据库拥有4 000多张彩色人脸照片, 包括不同角度、不同表情、不同光照和遮挡条件。选取前20个人的280张照片, 将其统一处理为灰度图大小为120×165个像素点。

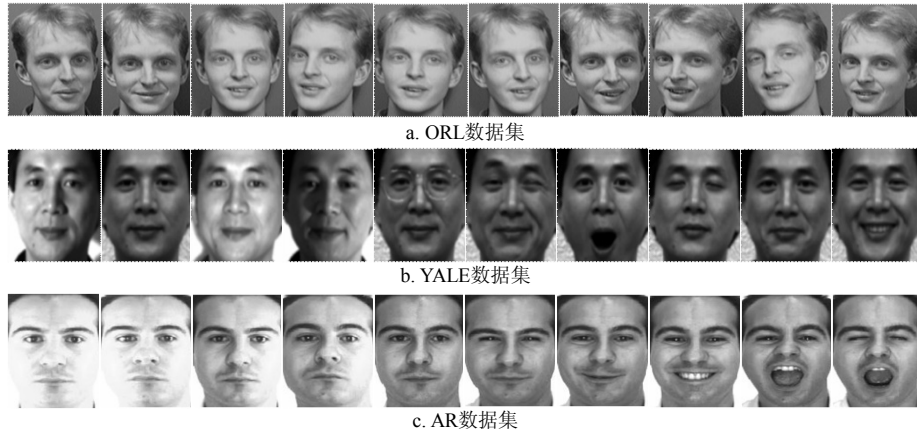


图1 不同数据集中单个体的10张人脸图像

3.2 改进2DLPP算法分析

较文献[7]算法不同, 改进2DLPP算法考虑图像类别信息来有监督提取更多局部结构信息, 鉴别样本间的类内和类间相似性。为验证改进算法性能随核参数变化的有效性, 在AR上采用不同的核参数 t 作对比。

实验采用AR人脸样本集不同的训练样本个数 ($M_t = 3, 4, 5, 6, 7, 8$) 和不同的核参数 ($t = 1 \times 10^4, 1 \times 10^6, 1 \times 10^8, 1 \times 10^{10}, 1 \times 10^{12}$), 每组取值均完成30次对比实验得到最终的平均识别率。

从表1可以看出, 改进算法在核参数 t 取 1×10^8 时均能达到很好的识别效果, 且图2表明在相同实验条件下, 改进算法较2DLPP达到了更好的识别率。

表1 选取不同核参数时的平均人脸识别率

核参数	样本个数					
	3	4	5	6	7	8
10^4	0.391 5	0.430 3	0.478 6	0.535 8	0.584 7	0.649 1
10^6	0.601 7	0.607 1	0.660 2	0.812 2	0.867 7	0.935 6
10^8	0.685 0	0.629 0	0.752 3	0.947 6	0.957 9	0.974 7
10^{10}	0.681 2	0.640 5	0.802 7	0.945 9	0.956 4	0.973 3
10^{12}	0.680 9	0.640 9	0.802 9	0.946 1	0.956 9	0.973 3

3.3 改进融合算法性能分析

1) 不同特征维数对算法识别性能的影响
在不同数据集上进行实验, 测试在相同训练样

本数下取不同特征维数时的识别率。图3给出了8种算法在不同数据集上识别率的变化曲线, 3a、3b、3c分别表示训练样本数为4、5、6时的算法性能。对比不同数据集上的算法性能, 改进融合算法均表现出了较好的识别性能。




图2 改进算法与2DLPP算法性能对比

2) 不同训练数目对算法识别性能的影响

通过选取ORL不同训练样本作为训练集, 剩下的样本作为测试集, 选取特征维数为 d , 对于2DPCA、2DLDA、2DLPP算法, 其对应特征矩阵为 $112 \times d$ 阶; 同时, (2D)²PCA、(2D)²LDA、(2D)²PCA-LDA、(2D)²LPP-PCA和改进融合算法均为 $d \times d$ 阶。

表2 不同算法在ORL数据集上的平均识别率

不同算法	训练样本数				
	2	3	4	5	6
2DPCA ^[5]	0.868 8 (112×4)	0.885 7 (112×6)	0.916 7 (112×6)	0.930 0 (112×7)	0.975 0 (112×7)
2DLDA ^[6]	0.875 0 (112×5)	0.900 0 (112×5)	0.941 7 (112×5)	0.975 0 (112×4)	0.966 7 (112×5)
2DLPP ^[7]	0.906 3 (112×3)	0.910 7 (112×5)	0.920 8 (112×5)	0.940 0 (112×6)	0.975 0 (112×6)
(2D) ² PCA ^[9]	0.837 5 (10×10)	0.867 9 (10×10)	0.895 8 (8×8)	0.920 0 (8×8)	0.968 8 (7×7)
(2D) ² LDA ^[10]	0.881 2 (10×10)	0.903 6 (12×12)	0.912 5 (12×12)	0.935 0 (12×12)	0.975 0 (13×13)
(2D) ² PCALDA ^[11]	0.831 3 (7×7)	0.875 0 (8×8)	0.904 2 (9×9)	0.915 0 (9×9)	0.968 8 (9×9)
(2D) ² LPP-PCA ^[13]	0.871 9 (6×6)	0.896 4 (6×6)	0.916 7 (9×9)	0.915 0 (5×5)	0.962 5 (6×6)
本文算法	0.865 6 (10×10)	0.917 9 (9×9)	0.916 7 (8×8)	0.920 0 (5×5)	0.981 2 (6×6)

*注: ()中内容为识别率所对应的特征维数。


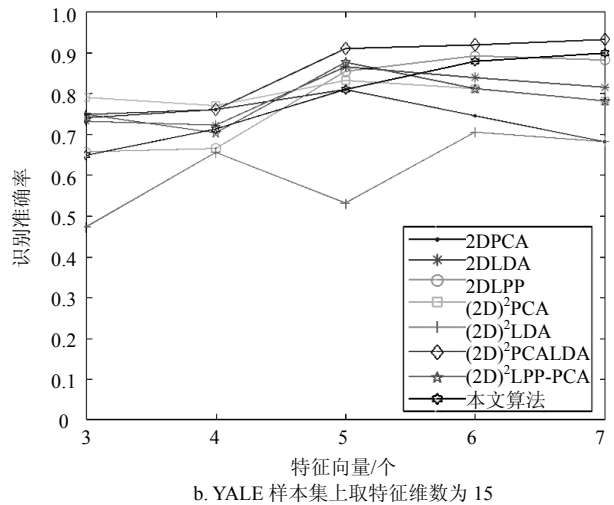

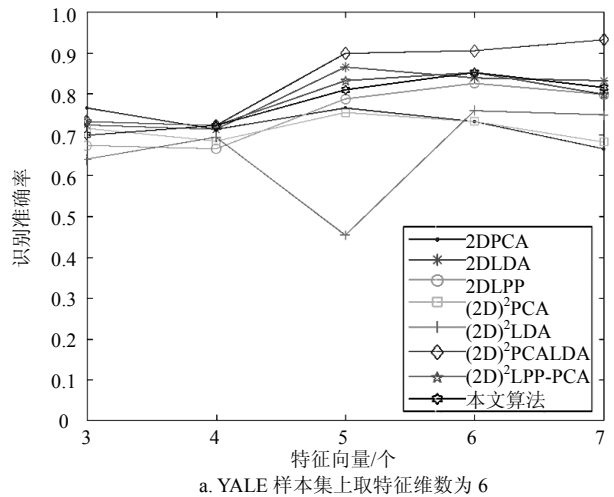
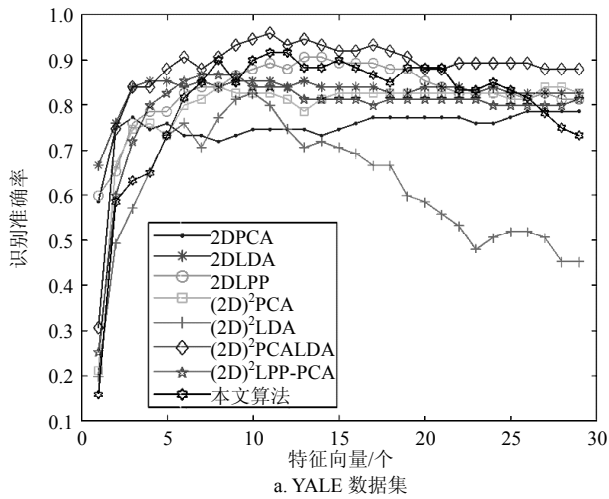


图3 不同算法在不同数据集上的性能对比

为进一步说明人脸图像集不同训练样本数对各种算法性能的影响,各算法在YALE和AR人脸数据集上选取相同特征维数进行实验。







图4 YALE、AR人脸库上各算法性能对比

图4表明在选取相同特征维数的情况下,改进融合算法在不同训练样本数下的性能表现均较好。算法性能优势在于改进融合算法采用行列方向分别融合2DPCA和2DLDA,在特征提取上更多的保留了人脸图像的局部信息,同时也保留了人脸更多的全局信息和鉴别信息。行方向融合2DPCA的主要原因是人脸图像的主要特征分布于水平方向;列方向融合2DLDA主要用于解决奇异矩阵问题,并增强类别鉴别性能。

同时实验比较了各算法在AR人脸数据集上处理相同数量训练样本时的运行时间及其识别率进行了对比。从表3中可以看出,2DPCA、2DLDA、2DLPP算法在处理相同训练样本数时耗时虽短,但是其识别精度不够,而改进算法不仅在识别率上有显著优势,同时其运行时间也表现较优。

表3 不同算法处理训练样本数为4时运行时间及其最优识别率的对比

算法	识别时间/s	识别率/%
2DPCA ^[5]	3.190 7	80.0
2DLDA ^[6]	3.013 5	82.0
2DLPP ^[7]	2.811 5	76.0
(2D) ² PCA ^[9]	6.187 1	91.5
(2D) ² LDA ^[10]	6.467 5	81.5
(2D) ² PCALDA ^[11]	3.519 7	81.5
(2D) ² LPP-PCA ^[13]	7.214 5	92.0
本文算法	4.330 4	92.5

4 结束语

针对二维局部保持投影(2DLPP)算法无监督且只保持数据局部性质的缺陷,本文提出改进二维双向局部保持投影算法。通过在3个人脸数据库上对各算法进行性能比较后,可以得出在处理小样本集问题时,改进算法较好地保留了图像的全局信息、结构信息和局部信息,并更多地考虑到了类内和类间的样本差异,对不同因素影响的人脸数据库均表现出了很好的鲁棒性,最终达到了较好的识别性能。

参考文献

- [1] 杨颖娴. 基于PCA算法和小波包变换的人脸识别技术[J]. 微电子学与计算机, 2011, 28(1): 92-94.
YANG Ying-xian. Face recognition based on PCA algorithm and wavelet packet transform[J]. Microelectronics & Computer, 2011, 28(1): 92-94.
- [2] CHEN L, LIAO H, KO M, et al. A new LDA based face recognition system which can solve the small sample size problem[J]. Pattern Recognition, 2000, 33(10): 1713-1726.
- [3] HE X F, PARTHA N. Locality preserving projections[J]. Advances in Neural Information Processing Systems, 2003, 16(1):186-197.
- [4] 梅玲玲, 龚劭. 基于改进的自适应局部保持投影算法的人脸识别[J]. 计算机科学, 2016(8): 286-291.
MEI Ling-ling, GONG Qu. Face recognition based on improved adaptive locality preserving projection[J]. Computer Science, 2016(8): 286-291.
- [5] YANG J, ZHANG D, FRANGQI A F, et al. Two-dimensional PCA: A new approach to appearance-based face representation and recognition[J]. IEEE transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-136.
- [6] YE J P, RAVI J, LI Q. Two-dimensional linear discriminate analysis[J]. Photo Grammetric Engineering & Remote Sensing, 2005, 5(6): 1431-1441.
- [7] HU D W, FENG G Y, ZHOU Z T. Two -dimensional locality preserving projections (2DLPP) with its application to palmprint recognition[J]. Pattern Recognition, 2007, 40(1): 339-342.

(下转第924页)

- [5] 杨丽琴, 康国盛, 蔡伟刚, 等. 业务流程挖掘算法研究[J]. 计算机应用与软件, 2016, 33(4): 44-50.
YANG Li-qin, KANG Guo-sheng, CAI Wei-gang, et al. On business process mining algorithms[J]. Computer Applications and Software, 2016, 33(4): 44-50.
- [6] VAN DER AALST W, WEIJTERS T, MARUSTER L. Workflow mining: Discovering process model from event logs[J]. IEEE Transactions on Knowledge and Data Engineering, 2004, 16(9): 1128-1142.
- [7] WEN L J, VAN DER AALST W, WANG J M. Mining process model with non-free-choice constructs[J]. Data Mining and Knowledge Discovering, 2007, 15(2): 145-180.
- [8] VAN ZELST S, VAN DONGEN B, VAN DER AALST W, et al. Discovering workflow nets using integer linear programming[J]. Computing, 2018, 100(5): 529-556.
- [9] ALVES DE MEDEIROS A, WEIJTERS A, VAN DER AALST W. Genetic process mining: An experimental evaluation[J]. Data Mining and Knowledge Discovering, 2007, 14(2): 245-304.
- [10] 顾春琴, 陶乾, 吴家培, 等. 基于混合自适应遗传算法的工作流挖掘优化[J]. 计算机科学, 2010, 37(3): 234-238.
GU Chun-Qin, TAO Qian, WU Jian-pei, et al. Workflow mining optimization based on hybrid adaptive genetic algorithm[J]. Computer Science, 2010, 37(3): 234-238.
- [11] VAN DER AALST W, DAMIANI E. Processes meet big data: Connecting data science with process science[J]. IEEE Transactions on Services Computing, 2015, 8(2): 810-819.
- [12] BRATOSIN C, SIDOROVA N, VAN DER AALST W. Distributed genetic process mining[C]//Proceedings of the IEEE World Congress on Computational Intelligence. Los Alamitos: IEEE, 2010: 1951-1958.
- [13] VERBEEK H M W, VAN DER AALST W, MUNOZ-GAMA J. Divide and conquer: A tool framework for supporting decomposed discovery in process mining[J]. The Computer Journal, 2017, 60(11): 1649-1674.
- [14] WANG J M, WONG R K, DING J, et al. Efficient selection of process mining algorithms[J]. IEEE Transactions on Service Computing, 2013, 6(4): 484-496.
- [15] DAVID K, HWU W M. Programming massively parallel processors: A hand-on approach[M]. San Francisco: Morgan Kaufmann Publishers, 2010.
- [16] RYOO S, RODRIGUES C I, BAGHSORKHI S S, et al. Optimization principles and application performance evaluation of a multi-threaded GPU using CUDA[C]//Proceedings of the 13th ACM SIGPLAN Symposium on Principles and Practice of Parallel Programming. New York: ACM, 2008: 73-82.

编辑 叶芳

(上接第909页)

- [8] SANGUANSAT P, ASDORNWISED W, JITAPUNKUL S, et al. Two-dimensional linear discriminant analysis of principle component vectors for face recognition[C]//IEEE International Conference on Acoustics, Speech and Signal Processing, 2006. [S.l.]: IEEE, 2006:II-II.
- [9] ZHANG D Q, ZHOU Z H. (2D)2PCA: Two-directional two-dimensional PCA for efficient face representation and recognition[J]. Neurocomputing, 2005, 69(1): 224-231.
- [10] NOUSHATH S, KUMAR G H, SHIVAKUMARA P. (2D)2LDA: An efficient approach for face recognition[J]. Pattern Recognition, 2006, 39(7): 1396-1400.
- [11] QI Y F, ZHANG J S. (2D)2PCALDA: An efficient approach for face recognition[J]. Applied Mathematics and Computation, 2009, 213(1): 1-7.
- [12] 赵冬娟, 梁久祯. 融合2DPCA和模糊2DLDA的人脸识别[J]. 计算机应用, 2011, 31(2): 420-422.
ZHAO Dong-juan, LIANG Jiu-zhen. Face recognition algorithm fusing 2DPCA and fuzzy 2DLDA[J]. Journal of Computer Applications, 2011, 31(2): 420-422.
- [13] 齐永锋, 火元莲. 一种结合2DLPP与2DPCA的人脸识别方法[J]. 西南交通大学学报, 2011, 46(6): 910-916.
QI Yong-feng, HUO Yuan-lian. Face recognition method combining 2DLPP with 2DPCA[J]. Journal of Southwest Jiaotong University, 2011, 46(6): 910-916.
- [14] 李球球, 杨恢先, 奉俊鹏, 等. 2DPCA+ 2DLDA和改进的LPP相结合的人脸识别算法[J]. 计算机工程与应用, 2015, 51(21): 199-204.
LI Qiu-qiu, YANG Hui-xian, FENG Jun-Peng, et al. Face recognition algorithm based on 2DPCA+ 2DLDA and improved LPP[J]. Computer Engineering and Applications, 2015, 51(21): 199-204.

编辑 刘飞阳