

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2010)12-1776-07

论文索引信息: 黄晓华, 梁超, 郑文明. 图像空间中的鉴别型局部线性嵌入方法[J]. 中国图象图形学报, 2010, 15(12): 1776-1782

图像空间中的鉴别型局部线性嵌入方法

黄晓华^{1),2)}, 梁超³⁾, 郑文明^{1),2)}

¹⁾ (东南大学儿童发展与学习科学教育部重点实验室, 南京 210096)

²⁾ (东南大学学习科学研究中心, 南京 210096) ³⁾ (东南大学信息科学与工程学院, 南京 210096)

摘要: 为了更好地利用图像的空间关系和类信息来提高局部线性嵌入的性能, 提出一种针对图像识别的鉴别型局部线性嵌入算法, 并应用于人脸识别。首先, 利用自适应图像欧氏距离构建近邻矩阵, 计算得到的权重矩阵, 再由权重矩阵重构特征, 然后重构出数据内在的低维空间, 最后利用线性判别分析引入类信息解决局部线性嵌入算法对测试样本无法重构以及分类的缺陷。实验基于 FRAV2D 和 ORL 人脸数据库, 分析了图像欧氏距离和自适应图像欧氏距离算法提取图像空间信息的能力, 并将本文提出的算法与目前已经广泛使用的人脸识别算法进行比较, 其结果表明了鉴别型局部线性嵌入算法能更好地保留图像流形结构和类信息, 显著提高人脸识别准确率。

关键词: 自适应图像欧氏距离; 局部线性嵌入; 线性判别分析; 人脸识别

Discriminative locally linear embedding in image space

HUANG Xiaohua^{1),2)}, LIANG Chao³⁾, ZHENG Wenming^{1),2)}

¹⁾ (Key Laboratory of Child Development and Learning Science, Ministry of Education, Southeast University, Nanjing 210096)

²⁾ (Research Center for Learning Science, Southeast University, Nanjing 210096)

³⁾ (College of Information Science & Engineering, Southeast University, Nanjing 210096)

Abstract: In this paper, a discriminative locally linear embedding algorithm on image recognition, which considers spatial relationship of pixels and class information in order to improve the performance of locally linear embedding (LLE), is presented. First, neighbor matrix, which is used to compute weight matrix, is constructed by adaptive image Euclidean distance, and features are reconstructed using the weight matrix. And then intrinsic lower-dimensional space of data is reconstructed. Finally, linear discriminant analysis is utilized to introduce class information to solve the defects that LLE can't reconstruct test samples and classify. Experiments are carried on FRAV2D and ORL databases. Comparing our proposed algorithm with popular algorithms in face recognition, these results show that a discriminative LLE can keep the best manifold structure and class information, and improve the accuracy of face recognition.

Keywords: adaptive image euclidean distance; locally linear embedding; linear discriminant analysis; face recognition

0 引言

人脸识别过程中, 往往面临高维的数据量, 要在保证数据信息足够完整的条件下, 合理地约简数据,

是数据降维研究所面临的主要挑战。以往的人脸识别或表情识别系统大多使用线性方法, 比如主成分分析^[1], 通过特征的线性组合来降维, 本质上是把数据投影到线性子空间, 这种方法相对简单且容易计算。但现实的有用特征不一定是特征的线性组

基金项目: 国家自然科学基金项目(60872160); 东南大学科技基金项目(XJ2008320)。

收稿日期: 2009-05-27; 改回日期: 2009-08-10

第一作者简介: 黄晓华(1983—), 男。现在东南大学学习科学研究中心攻读生物医学博士学位。主要研究方向为模式识别、计算机视觉、图像处理等。E-mail: xiaohua_huang@seu.edu.cn。

合,线性方法不能有效地处理庞大的高维数据。而非线性方法适用于数据呈非线性分布的情况,其中主成分分析、判别分析、典型相关分析等算法的核扩展已经得到了广泛应用^[2]。

近几年,流形学习算法作为非线性方法的一个分支,也被运用于识别方面^[3-7],比如局部线性嵌入^[8]与线性判别分析的结合,并已成功应用于人脸识别中^[6]。在众多流形学习算法中,局部线性嵌入是流形学习算法中应用最为广泛的算法之一,其基本思想是:假设样本处于高度密集的结构,用欧氏距离来近似估计样本的流形距离,通过引入了近邻思想寻找样本的局部结构。目前局部线性嵌入的改进方法有很多,包括利用样本类别信息的监督局部线性嵌入方法^[9],以及线性化 LLE 方法^[10];这些方法解决近邻数目选择优化问题,但没有考虑高维图像的空间关系。为了考虑图像的空间信息以及解决欧氏距离对图像平移和变形的的问题,需要新的距离测度算法来代替欧氏距离,从而构建近邻矩阵。基于上述问题,Wang 等人提出了一种新的距离测度算法——图像欧氏距离(IMED)^[11],认为图像中的任意两个像素间存在灰度相关性,两幅图像间的距离由所有像素距离迭加形成,并成功嵌入到等距特征映射^[12]。同样地,图像欧氏距离也可以嵌入到 LLE,考虑了高维图像的空间信息,并成功应用于人脸识别^[13]。但是图像欧氏距离没有考虑图像灰度层面的先验知识,为了弥补 IMED 的缺点,Li 等人^[14]进一步提出了自适应的图像欧氏距离测度,更好地提取图像相关性程度,并与图像欧氏距离进行比较,提高了人脸识别和手写识别系统的准确率。本文在自适应图像欧氏距离(AIMED)^[14]算法的基础上提出一种针对图像空间的鉴别型局部线性嵌入算法,来进一步优化局部线性嵌入在图像识别中的应用。此外,通过引入样本类别信息以及监督学习方法(线性判别分析^[1])相结合^[6]来提高算法的识别性能;最后,基于 FRAV2D^[15]和 ORL^[16]人脸数据库,将提出的算法应用于人脸识别中,从而验证算法的准确性。

1 鉴别型局部线性嵌入

1.1 局部线性嵌入算法

局部线性嵌入算法^[8]是一种非线性降维方法,

通常假定了数据集具有内在维数,从而可以通过数据映射到低维空间来避免维数灾难问题,其主要思想是对于一组具有流形结构的数据集,在高维空间与内在低维空间局部邻域间的数据拓扑关系保持不变。

假设局部线性嵌入的输入是一组高维数据集 $(\mathbf{x}_1, \dots, \mathbf{x}_L) \in \mathbf{R}^F$, 输出为一组低维数据集 $(\mathbf{y}_1, \dots, \mathbf{y}_L) \in \mathbf{R}^f$, 其中 $f \ll F$ 。

具体步骤如下所示:

1) 给定数据集 \mathbf{X} , 搜索数据集中每个 \mathbf{x}_i 与所有样本的距离, 即

$$\mathbf{Q}_i = [d(\mathbf{x}_i, \mathbf{x}_1), \dots, d(\mathbf{x}_i, \mathbf{x}_L)] \quad (1)$$

式中, \mathbf{Q}_i 表示样本 \mathbf{x}_i 与所有样本的距离向量。然后按递增顺序进行排序, 根据 K 近邻准则, 选取 \mathbf{x}_i 的 K 最近邻样本, 即 $[\mathbf{x}_i^1, \dots, \mathbf{x}_i^K]$;

2) 定义在高维空间的重构误差

$$\varepsilon(\mathbf{W}) = \sum_i \left| \mathbf{x}_i - \sum_{j=1}^K \mathbf{W}_{ij} \mathbf{x}_i^j \right|^2 \quad (2)$$

并考虑约束条件:

$$\sum_{j=1}^K \mathbf{W}_{ij} = 1 \quad (3)$$

同时, 如果 \mathbf{x}_i 和 \mathbf{x}_j 非邻域, 则 $\mathbf{W}_{ij} = 0$ 。然后, 根据最小二乘法求解出权矩阵 \mathbf{W} , 使得重构误差最小化。

3) 定义在低维空间的重构误差

$$\varepsilon(\mathbf{Y}) = \sum_i \left| \mathbf{y}_i - \sum_{j=1}^K \mathbf{W}_{ij} \mathbf{y}_j \right|^2 \quad (4)$$

再次利用最小二乘法, 则求得 $\varepsilon(\mathbf{Y})$ 最小化情况下最优解为矩阵

$$\mathbf{H} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W}) \quad (5)$$

的最小特征向量, 其中 \mathbf{T} 表示矩阵或向量转置, \mathbf{I} 表示单位矩阵。此时, 将步骤 2) 中得到的满足式(2)最小化的权矩阵代入式(5), 即可求得低维空间数据。

为了防止数据集坍缩至一个点, 所求特征向量中要去掉特征值为 0 所对应的特征向量。当有测试样本出现时, 采用样本投影方法^[17]寻找测试样本的低维空间, 然后进行分类。

1.2 自适应图像欧氏距离测度

在自适应图像欧氏距离算法中^[14], 给定一组样本集 $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^L \in \mathbf{R}^{M \times N \times L}$, 为了计算方便, 每一样本用大小为 $M \times N$ 矩阵的形式保存, 其中 M 表示样本行数, N 表示样本列数, L 表示样本数量, 样本维数记为 $F = M \times N$ 。

具体步骤如下:

1) 计算图像格的相对距离。图像格中任意两像素点 k 和 l 的位置分别为 (a, b) 和 (a', b') , 则它们的坐标相对距离为

$$d_{k,l} = \sqrt{(a - a')^2 + (b - b')^2} \quad (6)$$

式中, $1 \leq a, a' \leq M, 1 \leq b, b' \leq N$ 。

2) 引入度量系数矩阵。定义度量系数矩阵 $\mathbf{G} \in \mathbf{R}^{D \times D}$, 其中, \mathbf{G} 的第 k 行第 l 列元素值为

$$g_{k,l} = \frac{1}{2\pi\sigma^2} e^{-\frac{(d_{k,l})^2}{2\sigma^2}} \quad (7)$$

式中, σ 是一个待定参数。

由步骤 1) 得到图像格的距离矩阵, 并代入式 (7) 即可得到度量系数矩阵, 其反映了图像像素间的关联关系。

在图像欧氏距离算法中, 经过步骤 1) 和 2) 后, 可得到样本 \mathbf{x}_i 和 \mathbf{x}_j 的距离

$$d_{\text{IMED}}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{G} (\mathbf{x}_i - \mathbf{x}_j) \quad (8)$$

由于图像欧氏距离无法处理图像细微变换情况, Li 等人^[14] 引入黎曼尺度张量到图像欧氏距离。

3) 标准变换。将样本集 \mathbf{X} 中的每个样本向量化为列向量, 为了方便计算, 用 $\tilde{\mathbf{X}} = \{\tilde{\mathbf{x}}_i\}_{i=1}^L \in \mathbf{R}^{F \times L}$ 表示经过向量化后的样本集。采用尺度系数矩阵 \mathbf{G} 对图像进行变换, 得到新的样本集为 $\mathbf{V} = \{\mathbf{v}_i\}_{i=1}^L = \{\mathbf{G}^{1/2} \tilde{\mathbf{x}}_i\}_{i=1}^L, \mathbf{V} \in \mathbf{R}^{F \times L}$ 。

4) 引入新的度量系数矩阵。在新的样本集 \mathbf{V} 中, 对于列向量两点像素 p_m 和 p_n , 其中 $m = 1, \dots, F; n = 1, \dots, F$, 它们在 \mathbf{V} 中第 m 行和第 n 行的向量值记为 $\hat{\mathbf{v}}_m$ 和 $\hat{\mathbf{v}}_n$, 则两个像素所对应的灰度值的余弦相异度^[14] 为

$$\delta_{m,n} = 1 - \frac{\hat{\mathbf{v}}_m^T \hat{\mathbf{v}}_n}{\sqrt{\hat{\mathbf{v}}_m^T \hat{\mathbf{v}}_m} \sqrt{\hat{\mathbf{v}}_n^T \hat{\mathbf{v}}_n}} \quad (9)$$

由 $\delta_{m,n}$ 构建系数矩阵 \mathbf{G}_δ , 其中, 矩阵 \mathbf{G}_δ 的第 m 行第 n 列元素值为

$$g_{m,n}^\delta = \frac{1}{2\pi\sigma^2} e^{-\frac{\eta \delta_{m,n}}{2\sigma^2}} \quad (10)$$

这里, η 表示灰度尺度距离相对于空间距离的贡献率。

因此, \mathbf{x}_i 和 \mathbf{x}_j 的自适应图像欧氏距离为

$$d_{\text{AIMED}}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{v}_i - \mathbf{v}_j)^T \mathbf{G}_\delta^{1/2} \mathbf{G}_\delta^{1/2} (\mathbf{v}_i - \mathbf{v}_j) \quad (11)$$

式中, \mathbf{v}_i 和 \mathbf{v}_j 分别表示样本集 \mathbf{V} 中第 i 个和第 j 个图像。

1.3 鉴别型局部线性嵌入算法

1.3.1 邻域信息的改进

局部线性嵌入算法的步骤 1) (即寻找邻域信息), 忽略了高维图像的空间拓扑关系, 因此, 会出现寻找到与测试样本近邻的异类样本, 造成邻域构建出现误差。




图 1 手写数字样本^[14]

Fig. 1 Handwritten number samples

图 1 中, 训练样本 (a) 和测试样本 (b)、(c), 从视觉角度上, 可以容易辨别出它们之间的区别, 而且可以判断出样本 (c) (a) 是属于相同类, 样本 (b) (a) 是属于异类。Li 等人^[14] 分别采用欧氏距离、图像欧氏距离和自适应欧氏距离算法进行比较, 结果表明自适应欧氏距离对测试样本具有更好的选择性。

在局部线性嵌入算法中, 搜索数据集中 \mathbf{x}_i 与 \mathbf{x}_j 的距离, 即

$$d(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j) \quad (12)$$

在 1.2 中, 自适应图像欧氏距离可以用于改善邻域信息的构建, 因此, 用式 (11) 替代欧氏距离算法来寻找近邻样本。根据 K 近邻准则, 选取 \mathbf{x}_i 的 K 最近邻样本, 即 $[\tilde{\mathbf{x}}_1^k, \dots, \tilde{\mathbf{x}}_K^k]$; 然后, 根据式 (2) 构建权重矩阵 $\tilde{\mathbf{W}}$; 最后根据式 (5) 求得内在低维空间特征。

1.3.2 引入类信息

局部线性嵌入是一种非线性降维方法^[8], 由于其存在参数的优化问题, 以及很难保证得到测试样本原有的结构, 因此, 在应用方面仍然有局限性。经过近几年的发展, 随着监督方法引入以及参数选择问题的解决, 目前已应用于人脸识别。Zhang 等人^[6] 将线性判别分析算法引入到局部线性嵌入, 提高 LLE 算法的识别性能。因此, 在改善邻域信息的基础上, 借鉴 Zhang 等人的方法^[6], 采用线性判别分析方法将样本类别信息引入到数据降维中。

给定一组数据 $\mathbf{X} \in \mathbf{R}^{F \times L}$, 有 C 类样本, 每类有 n_i 个样本, 数据经过基于自适应欧氏距离的局部线性嵌入后的低维特征为 $\mathbf{Y} \in \mathbf{R}^{f \times L}$ 。在低维空间中, 其

类内散射矩阵和类间散射矩阵分别为

$$S_w = \sum_{i=1}^C \sum_{j=1}^{n_i} (y_j^i - \mu_i) (y_j^i - \mu_i)^T \quad (13)$$

$$S_b = \sum_{i=1}^C (\mu_i - \mu) (\mu_i - \mu)^T \quad (14)$$

式中, $\mu_i = \frac{\sum_{j=1}^{n_i} y_j^i}{n_i}$ 表示第 i 类样本的均值; $\mu = \frac{\sum_{i=1}^C \sum_{j=1}^{n_i} y_j^i}{L}$

表示总样本的均值; y_j^i 表示第 i 类第 j 个样本。

线性判别分析的基本思想是提取判别特征使得样本的类间离散度和类内离散度的比值最大,即各类样本在特征空间中有最佳的可分离性。然后,由 $S_w^{-1} S_b$ 的特征分解得到特征空间 P 。

将样本 Y 映射到特征空间 P , 即

$$Z = P^T Y \quad (15)$$

对于测试样本 t , 利用自适应图像欧氏距离寻找其 K 个近邻, 然后根据式 (2) 计算得到 t 的权重向量 \tilde{W}_t , 因此, 对于测试样本 t 的投影向量为

$$\hat{z}_t = \sum_{j=1}^K \tilde{W}_{tj} Z_{tj} \quad (16)$$

式中, \tilde{W}_{tj} 表示与 t 的第 j 个近邻样本的权重; Z_{tj} 表示样本 Y_j 在低维空间的特征向量。

1.3.3 复杂度分析

改进的局部线性嵌入引进了邻域信息构造距离矩阵和类信息改善投影信息, 其过程包括了计算样本之间的距离、近邻样本的选择、权重矩阵的构建以及对式 (7) 的特征求解。给定一组样本集 $X = \{x_i\}_{i=1}^L \in \mathbf{R}^{f \times L}$, 经过改进的局部线性嵌入后样本的维数记为 f , 经过线性判别分析后得到的特征空间维数为 P , 表 1 列出本文鉴别型局部线性嵌入算法的计算复杂度。

表 1 算法的复杂度

Tab.1 Computational complexity of an algorithm

步骤	复杂度
自适应欧氏距离测度	$O(F^2)$
样本距离的计算	$O(FL^2)$
近邻样本的选择	$O(LK)$
权重矩阵的构建	$O(FLK^2)$
式 (7) 的特征求解	$O(fL^2)$
线性判别分析	$O(FL^2 + fL^2)$
特征空间的投影	$O(PfL)$

由表 1 可以看出, 鉴别型局部线性嵌入其瓶颈在于计算自适应欧氏距离, 对于低维图像, 复杂度较

小; 对于高维图像, 其计算量很大, 但由于自适应距离测度的模板可以根据图像的维数预先构建储存, 只需要在计算过程中会调用相应的模板就可以减少计算复杂度。因此, 相对于表 2 的其他算法, 改进的局部线性嵌入在复杂度仍有可比性。

表 2 算法简称

Tab.2 Abbreviation of different algorithms

算法	简称
主成分分析 ^[1]	PCA
线性判别分析 ^[1]	LDA
规则化判别分析 ^[18]	R-LDA
局部线性嵌入 ^[8]	LLE
监督局部近邻嵌入 ^[10]	SNPE
拉普拉斯特征脸 ^[19]	LPP
正交化拉普拉斯特征脸 ^[20]	OLPP
局部线性嵌入与线性判别分析统一算法 ^[6]	ULLELDA
基于图像欧氏距离的局部线性嵌入	LLE-IMED
鉴别型局部线性嵌入算法	DLLE

2 实验与分析

采用 FRAV2D^[15] 和 ORL^[16] 人脸数据库验证所提出的算法用于人脸识别的可行性和优越性。在进行实验前, 通过眼睛、鼻子和嘴巴坐标, 对人脸图像进行预处理(图 2)。

2.1 FRAV2D

采用 FRAV2D 彩色人脸数据库进行实验, FRAV2D 数据库包含 109 人(男性:75, 女性:34), 每人 32 幅彩色图像, 包含中性表情、旋转 15°、30°、光照影响、各种姿态、遮挡情况下的图像。实验中, 选取除去遮挡外的所有图像, 实验中每个人有 28 幅彩色图像, 将选取的图像进行灰度化, 并将图像大小归一化为 60 × 60 像素。为了保证实验的准确率和稳定性, 文中采用 20-折交叉验证 (twenty-fold cross validation) 方法进行测试。图 2 是 FRAV2D 数据库中的部分图像。



图 2 FRAV2D 人脸数据库部分图像

Fig.2 Sample images from FRAV2D database

在实验中,不需要用 Gabor 方法进行特征提取,因为图像欧氏距离和自适应图像欧氏距离与 Gabor 方法相似,提取图像的空间信息。但是,图像欧氏距离和自适应图像欧氏距离哪个算法更具有较好的测度,选取图像格坐标点(17,40)进行实验比较。图 3 为用图像欧氏距离进行变换的图像空间信息,其中参数 $\sigma = 0.1$;图 4 由自适应图像欧氏距离得到的图像单个像素的空间信息,其中,参数 $\sigma = 0.1, \eta = 2^6$ 。




图 3 IMED 的空间信息图

Fig. 3 Spatial information image of IMED




图 4 AIMED 的空间信息图

Fig. 4 Spatial information image of AIMED

图 3 中,采用图像欧氏距离得到的图像空间信息,对于每个像素点,它所能得到的空间信息是其相邻 4 个像素点的信息;而图 4 中,自适应图像欧氏距离得到的图像空间,与图 3 进行对比,它所能得到相邻像素点的空间信息会比前者多;对于它们两者的测度性能,文献[14]中已经证明它们之间的性能差异,图 1 中,通过手写数字在欧氏距离、图像欧氏距离、自适应图像欧氏距离算法下所得到的相似性比较,说明自适应图像欧氏距离算法具有其优势。因此,自适应图像欧氏距离算法较图像欧氏距离有更好的提取能力和测度能力。

为了验证所提出算法在人脸识别的应用是否具有可行性,采用了表 2 所列举的算法进行比较。其中,基于图像欧氏距离的局部线性嵌入算法是在基

于文献[13]基础上,引入类信息所获得的算法。由于 R-LDA、LLE、ULLELDA、LLE-IMED、DLLE 算法需要进行参数选择,因此,在实验中,选择了最佳参数;表 3 列出了部分算法的参数设置。

表 3 部分算法参数表

Tab. 3 Parameters of Algorithms

算法	参数
R-LDA	$r = 0.01$
LLE	$K = 40$
LPP	$K = 7, t = 1$
ULLELDA	$K = 40$
LLE-IMED	$K = 40, \sigma = 0.1$
DLLE	$K = 40, \sigma = 0.1, \eta = 2^6$

表 4 给出了用 10 种算法分别对 FRAV2D 数据库识别的错误率结果,其中第 2 列的数据表示最后得到的特征向量维数。

表 4 FRAV2D 数据库在各种算法的错误率

Tab. 4 Error rate under FRAV2D database by algorithms

算法	维数	错误率/%
PCA	108	5.78 ± 1.76
SNPE	30	11.03 ± 2.80
LPP	30	8.63 ± 2.67
OLPP	30	2.34 ± 1.17
LLE	108	6.08 ± 1.95
LDA	108	2.41 ± 1.68
R-LDA	108	3.11 ± 1.50
ULLELDA	108	6.22 ± 2.04
LLE-IMED	108	2.32 ± 1.39
DLLE	108	2.17 ± 1.23

由表 4 可以看出,SNPE 算法有较大的误差, LPP 经过正交化后,其误差率明显降低。与 LLE 比较,ULLELDA 误差率增大,其性能也比 OLPP 和 LDA 差; LLE-IMED 和 DLLE 比 ULLELDA 误差率分别下降了 3.9% 和 4.05%, LLE-IMED 与 OLPP 和 LDA 性能相近; DLLE 比 OLPP 和 LDA 在误差率方面分别降低 0.17% 和 0.24%,此外, DLLE 比 LLE-IMED 低 0.34%。因此,通过算法间的误差率比较,结果说明在人脸识别应用上, DLLE 可以明显降低误差率,也明显提高了 LLE 的性能。

2.2 ORL

采用 ORL 人脸数据库进行实验。ORL 数据库包含 40 人,每人 10 幅灰度图像,图像大小均为 32 × 32 像素。为了比较识别性能,从每类中随机抽取 7 个样本作为训练样本,而其余作为测试样本,均运行 50 次。

2.2.1 识别率

实验中,采用了表 3 所列举的参数对算法进行参数设置。表 5 中给出了用 10 种算法分别对 ORL 数据库识别的错误率结果,其中第 2 列的数据表示最后得到的特征向量维数。

表 5 ORL 数据库在各种算法的错误率

Tab.5 Error rate under ORL database by algorithms

算法	维数	错误率/%
PCA	150	7.75 ±2.72
SNPE	30	6.18 ±1.93
LPP	38	4.78 ±1.71
OLPP	30	4.02 ±2.10
LLE	150	6.23 ±2.66
LDA	39	4.47 ±1.99
R-LDA	39	4.18 ±1.73
ULLELDA	39	4.78 ±1.91
LLE-IMED	39	4.17 ±2
DLLE	39	3.45 ±1.66

由表 5 可以看出,其实验结果与表 3 类似,但是 ULLELDA 相对于 OLPP 和 LDA 在识别性能上有较小的差异;同样地,在误差率方面,DLLE 比 LDA、OLPP 分别降低了 1.02% 和 0.57%,比 LLE 和 ULLELDA 分别降低了 2.78% 和 1.33%,比 LLE-IMED 降低了 0.72%。这些说明了邻域信息改善后和引入类信息同时提高了 LLE 的性能,改进的算法提高了人脸识别系统的准确性。

2.2.2 参数分析

对比式(7)和式(10),LLE-IMED 和 DLLE 具有相同 σ ,因此,采用随机样本校验法分析 σ 对识别率的影响。图 5 给出了参数对误差率的影响。




图 5 不同参数下的错误率(LLE-IMED)

Fig.5 Error rate under different parameters in LLE-IMED

由图 5 可以看出,随着 σ 的增大,误差率呈上升的趋势,这意味着随着 σ 增大,图 3 和图 4 所得到的像素间的相关性越来越小,最后趋近于单像素计算所得识别率。

为了比较在不同 η 下,DLLE 是否具有更高的识别率,采用随机样本校验法对 LLE-IMED 和 DLLE 算法进行错误率比较,图 6 给出了 2 种算法的人脸识别误差率结果。




图 6 不同参数下的错误率

Fig.6 Error rate under different parameters

由图 6 可以看出,DLLE 算法在参数改变情况下,其错误率稍微呈上升的趋势,但是仍然低于 LLE-IMED 算法。因此,DLLE 仍具有较佳的识别性能。

3 结论

本文算法在局部线性嵌入算法的基础上,充分考虑了图像的像素以及灰度之间的相关信息,结合线性判别分析的类信息优势应用于人脸识别中。利用了自适应图像欧氏距离更多考虑图像的空间信息和利用线性判别分析引入类信息,提出了鉴别型局部线性嵌入算法,并分析了算法的复杂度;在 FRAV2D 实验平台上,比较了 IMED 与 AIMED 提取空间信息的能力;同时在 FRAV2D 和 ORL 图像库实验平台上,与 PCA、SNPE、LPP、LLE、LDA、R-LDA、ULLELDA 以及 LLE-IMED 算法进行识别错误率对比,实验结果表明采用改进的局部线性嵌入可以更好地提取邻域信息和保持类信息,从而明显提高识别性能。

参考文献 (References)

- [1] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenface vs. Fisherface: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7):711-720.
- [2] John S T, Nello C. Kernel Methods for Pattern Analysis [M]. UK: Cambridge University Press, 2004.
- [3] Zhao Q J, Zhang D, Lu H T. Supervised LLE in ICA space for facial expression recognition [C]//Proceedings of International Conference on Neural Network and Brain. Washington DC, USA: IEEE Computer Society Press, 2005:1970-1975.
- [4] Yang M H. Extended Isomap for pattern classification [C]//Proceedings of the 8th International Conference on Artificial Intelligence Edmonton. Menlo Park, CA, USA: American Association for Artificial Intelligence, 2002:224-229.
- [5] Ridder D D, Loog M, Reinders M J T. Local fisher embedding [C]//Proceedings of International Conference on Pattern Recognition. Washington DC, USA: IEEE Computer Society Press, 2004:295-298.
- [6] Zhang J P, Shen H X, Zhou Z H. Unified locally linear embedding and linear discriminant analysis algorithm (ullelda) for face recognition [J]. Advances in Biometric Personal Authentication. LNCS, 2004, 3338:209-307.
- [7] Colmenarez A, Frey B, Huang T S. Embedded face and facial expression recognition [C]//Proceedings of International Conference on Image Processing. Washington DC, USA: IEEE Computer Society Press, 1999:633-637.
- [8] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290:2323-2326.
- [9] Ridder D, Olga K, Olga O. Supervised locally linear embedding [C]//Lecture Notes in Artificial Intelligence. Berlin, Heidelberg: Springer-Verlag, 2003:333-341.
- [10] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding [C]//Proceedings of the 10th IEEE International Conference on Computer Vision. Washington DC, USA: IEEE Computer Society Press, 2005:1208-1213.
- [11] Wang L W, Zhang Y, Feng J F. On the Euclidean distance of images [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8):1334-1339.
- [12] Chen J, Wang R P, Shan S G, et al. Isomap based on the image Euclidean distance [C]//Proceedings of the 18th International Conference on Pattern Recognition. Washington DC, USA: IEEE Computer Society Press, 2006:1110-1113.
- [13] Zhang L J, Wang N. Locally linear embedding based on image Euclidean distance [C]//Proceedings of IEEE International Conference on Automation and Logistics. Washington DC, USA: IEEE Computer Society Press, 2007:1914-1918.
- [14] Li J, Lu B L. An adaptive image Euclidean distance [J]. Pattern Recognition, 2009, 42(3):349-357.
- [15] Serrano A, Diego I M, Conde C, et al. Influence of wavelet frequency and orientation in an SVM-based parallel Gabor PCA face verification system [C]//Proceedings of Conference on Intelligent Data Engineering and Automated Learning. Berlin, Heidelberg: Springer-Verlag, 2007:219-228.
- [16] Samaria F, Harter A. Parameterisation of a stochastic model for human face identification [C]//Proceedings of 2nd IEEE Workshop on Application of Computer Vision. Washington DC, USA: IEEE Computer Society Press, 1994:138-142.
- [17] Choi H, Choi S. Kernel isomap on noisy manifold [C]//Proceedings of the 4th International Conference on Development and Learning. Washington DC, USA: IEEE Computer Society Press, 2005:208-213.
- [18] Dai D Q, Yuen P C. Regularized discriminant analysis and its application to face recognition [J]. Pattern Recognition, 2003, 36:845-847.
- [19] Cai D, He X, Hu Y, et al. Learning a Spatially Smooth Subspace for Face Recognition [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, Washington DC, USA: IEEE Computer Society Press, 2007:1-7.
- [20] Cai D, He X, Han J, et al. Orthogonal laplacianfaces for face recognition [J]. IEEE Transactions on Image Processing, 2006, 11(15):3608-3614.