

基于最大间距准则的局部图嵌入特征提取方法

万鸣华^{1,2)}, 金 忠¹⁾

¹⁾(南京理工大学计算机科学与技术学院 南京 210094)

²⁾(南昌航空大学信息工程学院 南昌 330063)

(wmh36@sina.com)

摘 要: 针对局部线性嵌入(LLE)算法和最大间距准则(MMC)算法在特征提取问题中存在不足,提出一种有效的数据降维和分类方法——基于最大间距准则的局部图嵌入特征提取算法,并将其应用在人脸识别上.该算法在保持近邻的前提下,分别构造类内紧致图和类间惩罚图.首先在类内紧致图中利用线性重构的局部对称性找出高维数据空间中的非线性结构,使同类样本尽可能地聚集在一起;然后在类间惩罚图中使不同类别的样本尽可能分离;为了避免“小样本”问题,采用 MMC 的形式构造目标函数.在 ORL, Yale 和 AR 人脸图像库进行实验的结果表明,文中算法相对于 DLA 和 LLE+LDA 算法有较好的识别性能.

关键词: 局部线性嵌入; 数据降维; 人脸识别; 最大间距准则; 局部图嵌入

中图法分类号: TP391.41

Local Graph Embedding Feature Extraction Method Based on Maximum Margin Criterion

Wan Minghua^{1,2)} and Jin Zhong¹⁾

¹⁾(School of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing 210094)

²⁾(School of Information Engineering, Nanchang Hangkong University, Nanchang 330063)

Abstract: To tackle the insufficiency problem of local linear embedding (LLE) algorithm and maximum margin criterion (MMC) algorithm in feature extraction, an efficient dimensional reduction and classification algorithm, local graph embedding feature extraction method based on maximum margin criterion (LGE/MMC), is presented with applications in face recognition. The goal of this algorithm was to construct the intrinsic graph and penalty graph, with the preservation of nearest neighbor premise. In the intrinsic graph, the nonlinear structure is discovered in the high dimensional data space by the local symmetry of the linear restructuring, which causes the similar samples gathering together as much as possible. At the same time, different class samples are as far as possible from each other in the penalty graph. In this method, the “small size sample” problem is solved by the employment of MMC and the neighborhood relationship is better described by an adequate modification of the adjacency matrix. The results of face recognition experiments on ORL, Yale and AR face databases demonstrate the effectiveness of the proposed method in comparison with the DLA and LLE+LDA method.

Key words: local linear embedding; dimensional reduction; face recognition; maximum margin criterion; local graph embedding

收稿日期: 2010-09-15; 修回日期: 2011-03-18. 基金项目: 国家自然科学基金重点项目(60632050); 国家自然科学基金(60873151); 高等学校博士学科点专项科研基金(20060288013). 万鸣华(1978—), 男, 博士研究生, 主要研究方向为模式识别、机器学习等; 金 忠(1961—), 男, 博士, 教授, 博士生导师, 主要研究方向为模式识别、图像分析、计算机视觉等.

人脸识别^[4]已经成为模式识别、机器视觉和计算机视觉领域主要研究对象. 目前, 有许多线性的和非线性的数据降维方法应用于人脸识别问题中. 主成分分析(principle component analysis, PCA)^[5]和线性鉴别分析(linear discriminant analysis, LDA)^[6]是实现数据降维的 2 种经典方法, 但它们都是线性降维方法, 对一些呈现某种“非线性”的数据效果不是很好.

近年来, 对于非线性数据降维, 以流形学习为主导的维数约减理论研究和应用取得了长足的发展, 最具代表性的方法有等距离映射(isometric mapping, ISOMAP)^[7]、局部线性嵌入(locally linear embedding, LLE)^[8,9]、拉普拉斯算子特征映射(Laplacian eigenmaps, LE)^[10,11]等, 这些方法均能在保持原始数据拓扑结构不变的前提下, 把高维数据映射到低维空间. 其中, LLE 是一种无监督的学习算法, 以保持局部邻域间相互关系的方式把高维数据映射到一个低维全局坐标系下. LLE 算法可以看清原始数据的本征结构并发掘数据点间的内部结构, 但是对于数据分类等问题的效果不是很好. 目前基于 LLE 的监督算法分为 2 种情况: 一是在处理 LLE 算法中计算出每个样本点的 K 个近邻点时增加了样本点的类别信息^[12,15]; 二是 LLE 算法结合 LDA 算法, 先用 LLE 进行数据降维, 再用 LDA 算法进行分类^[16,17].

尽管这些非线性降维技术在理论上可以发现复杂的低维嵌入, 并且在人造测试数据上产生了很好的效果, 但是在很多实际的应用中面临 2 个问题: 1) 计算负荷很大; 2) 只能产生定义在训练数据点集上的维数约简映射, 不能为新的测试点建立映射关系. 针对这些缺陷, He 等提出了保局投影(locality preserving projections, LPP)算法^[18]和近邻保持嵌入(neighborhood preserving embedding, NPE)算法^[19], 并将它们成功地应用于人脸识别中; 但是这 2 种算法和 LDA 一样, 也面临“小样本”问题^[20]. Li 等^[21]提出的最大间距准则函数(maximum margin criterion, MMC), 但是对于非线性数据可能失效^[22,23].

为了解决上述方法面临的问题, 本文在 LLE 和 MMC 算法基础上, 提出一种有效的数据降维和分类方法——基于最大间距准则的局部图嵌入特征提取方法(locally graph embedding feature extraction methods based on maximum margin criterion, LGE/MMC), 并将其应用在人脸上. 在 MMC 下, 类内紧致图利用线性重构的局部对称性找出高

维数据空间中的非线性结构, 使同类样本尽可能地聚集在一起. 由于 LLE 是无监督方法, 不能增强可视化和聚类分类能力, 所以在类内紧致图中考虑样本的类别信息, 可使同类别的样本尽可能紧致; 同时, 类间惩罚图中使不同类别的样本尽可能远离. 在这 2 幅最优邻接图下, 本文算法使得降维后的数据类内尽可能接近而类间尽可能远离, 在 ORL, Yale 和 AR 标准人脸库上的实验结果验证了其有效性.

1 LLE 和 MMC

设高维欧氏空间中有样本集 $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in R^D$, 寻求一个投影矩阵 A , 希望将这些样本映射到一个相对低维的特征空间 R^d , $d \leq D$. 这样, 样本在新特征空间中的表述为 $Y = \{y_1, y_2, \dots, y_n\}$, $y_i = A^T x_i$. 设矩阵 $A = \{a_1, a_2, \dots, a_d\}$ 为最佳鉴别矢量 a_i 所构成的投影矩阵.

1.1 LLE

LLE 算法是一种非线性降维方法, 其基本思想是保持原流形中局部邻域间的相互关系, 将高维数据映射到低维全局坐标系中.

LLE 算法通常分为 3 步来实现:

Step1. 计算数据集中每个样本 x_i 的 k 个近邻点 $\{x_{i_1}, x_{i_2}, \dots, x_{i_k}\}$, 其中 k 是一个预先给定值.

Step2. 计算出样本点的局部重建权值矩阵. 定义一个误差函数

$$\mathcal{E}(W) = \sum_i \left| x_i - \sum_j W_{ij} x_j \right|^2 \quad (1)$$

通过最小化式(1), 计算重建每个样本点 x_i 的权值 W_{ij} . 其中 $\sum_{j=1}^k W_{ij} = 1$, 当 $x_j \notin \{x_{i_1}, x_{i_2}, \dots, x_{i_k}\}$ 时, $W_{ij} = 0$.

Step3. 将所有的样本点映射到低维空间中. 映射条件为最小化

$$\mathcal{E}(Y) = \sum_{i=1}^n \left| y_i - \sum_{j=1}^k W_{ij} y_j \right|^2 \quad (2)$$

根据权值 W_{ij} 最小化式(2)的目标函数, 求得 x_i 的 d 维投影向量 y_i ; 为了保证有唯一解, 必须满足 $\sum_{i=1}^n y_i = 0$ 以及 $\frac{1}{n} Y Y^T = I$. 由 Rayleitz Ritz 定理, 求解 $M = (I - W)^T (I - W)$ 的最小 $d+1$ 个特征值对应的特征向量并按序排列, 丢掉第一个特征值对应的特征向量, 剩下的 d 个特征向量组成的矩阵就是本文得到的低维嵌入样本.

1.2 MMC

同基于 Fisher 准则的线性鉴别特征提取的目的的一样, MMC 算法的目的也是要将数据从原始的高维空间压缩到低维空间, 并且在低维空间保持较高的可分性.

在 MMC 算法中, S_b , S_w 和 S_t 分别表示训练样本的类间散布矩阵、类内散布矩阵和总体散布矩阵。由其定义知, S_b , S_w 和 S_t 均为非负定矩阵, 且满足 $S_t = S_b + S_w$, 其中,

$$S_b = \sum_{i=1}^c l_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^T,$$

$$S_w = \sum_{i=1}^c \sum_{j=1}^{c_i} (x_i^j - \bar{x}_i)(x_i^j - \bar{x}_i)^T;$$

$l_i = N_i/N$ 是第 i 类的先验概率, \bar{x} 表示所有样本的均值, \bar{x}_i 表示第 i 类训练样本的均值, N_i 是第 i 类训练样本的个数, N 是所有样本的个数。

MMC 函数定义为 $\max J(A) = \text{tr}(S'_b - S'_w)$ 。

由于 S'_b 和 S'_w 分别表示经过 $y_i = A^T x_i$ 投影变换后的特征空间中样本类间散布矩阵和类内散布矩阵, 其中 $S'_b = A^T S_b A$, $S'_w = A^T S_w A$, 所以

$$J(A) = \text{tr}(S'_b - S'_w) = \text{tr}(A^T (S_b - S_w) A) = \sum_{i=1}^d a_i^T (S_b - S_w) a_i.$$

当约束条件为 $a_i^T a_i = 1$, 可得

$$\begin{cases} \max \sum_{i=1}^d a_i^T (S_b - S_w) a_i \\ \text{subject to } a_i^T a_i = 1 \end{cases} \quad (3)$$

式(3)可利用拉格朗日乘数法来求解得到

$$(S_b - S_w) a_i = \lambda a_i \quad (4)$$

因此, 通过式(4)可以很容易求解前 d 个特征值所对应的特征向量。其中 λ 是 $S_b - S_w$ 的特征值, 而 a_i 为对应的特征向量。由前 d 个最大特征值对应的特征向量组成最后的投影矩阵, 本文将得到的投影矩阵记为 $A_{MMC} = \{a_1, a_2, \dots, a_d\}$ 。

2 基于 MMC 的局部图嵌入

2.1 基本思想

MMC 算法中相应的类间散布矩阵的最大代表了不同类之间的样分离, 而类内散布矩阵的最小表示着同类之间的模式样本尽量紧凑, 但它不能有效地保持样本固有的局部流形结构。本文将 MMC 算法进行推广, 有效结合样本固有的局部图嵌入结构。即如果 x_i 和 x_j 变换前是邻近的, 则变换后 y_i 和 y_j 也是邻近的; 否则, 变换后 y_i 和 y_j 也是非邻近的。

本文提出的 LGE/MMC 算法的目的是在保持局部近邻关系的前提下, 使同类样本尽可能地聚集在一起, 而不同类别的样本尽可能远离。

设 $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in R^d$ 表示样本数据

$Y = \{y_1, y_2, \dots, y_n\}$, $y_i \in R^d$ 为降维后的数据, $G = \{X, W\}$ 表示一个加权无向图, 其中 X 为顶点集, $W \in R^{n \times n}$ 为相似度矩阵。对角矩阵 D 和图 G 的拉普拉斯矩阵 L 分别定义为

$$D_{ii} = \sum_{j \neq i} W_{ij}, L = D - W, \forall i.$$

2.2 LGE/MMC 算法步骤

LGE/MMC 算法可分为 3 个步骤:

1) 类内散度矩阵的刻画

在类内紧致图中, 一个数据点和它同类的类内近邻数 k_c 个近邻数据在其隐含的流形上是局部线性的, 并且每一个数据点都可以通过其加权了的近邻数据进行重构。LGE/MM 类内局部表示与 LLE 算法相似; 与 LLE 算法唯一不同的是, 本文构造权值矩阵 W 时, 既计算数据集中每个样本 x_i 的 k_c 个近邻点, 又考虑样本类别信息, 而 LLE 算法没有考虑数据样本类别信息。因此, 类内散度矩阵的刻画同 LLE 算法构建类似, 共有 3 个步骤。其中在最后映射最小化目标函数

$$S_c = \sum_{i=1}^n \left| y_i - \sum_{j=1}^k W_{ij}^c y_j \right|^2 \quad (5)$$

本文引进一个线性转换函数, $y_i = A^T x_i$, 则式(5)可以改变为

$$J_1(A) = \min \text{tr}\{YMY^T\} = \min \text{tr}\{A^T XMX^T A\};$$

其中 $W_{ij} = \begin{cases} 1, & x_i \text{ 最近 } k_c \text{ 的同类近邻数} \\ 0, & \text{其他} \end{cases}$ 。

2) 类间散度矩阵的刻画

在类间惩罚图中, 如果输出的 2 个数据 y_i 和 y_j 属于不同的类别, 找到一个最佳映射的合理办法是使下面的损失函数 S_p 的值为最大。同时为了化简方程, 引进一个线性转换函数 $y_i = A^T x_i$, 则有

$$\begin{aligned} S_p &= \frac{1}{2} \sum_i \sum_j \|y_i - y_j\|^2 W_{ij}^p = \\ &= \frac{1}{2} \sum_i \sum_j \|A^T x_i - A^T x_j\|^2 W_{ij}^p = \\ &= A^T X(D^p - W^p) X^T A = \\ &= A^T X L^p X^T A \end{aligned} \quad (6)$$

式(6)的本质是在数据为不同类别时输出方差最大。PCA 也能保持所输出的方差数据最大, 但它是一个全局的方法, 输出的是类内和类间输出的数据。而本文提出的类间方法是局部的方法, 只考虑类间数据, 忽略类内的数据的干扰, 能更准确地分类非线性的高维数据。所以本文构造相似矩阵为

$$W_{ij}^p = \begin{cases} 1, & x_i \text{ 最近 } k_p \text{ 的不同类近邻数} \\ 0, & \text{其他} \end{cases}$$

3) 最优投影矩阵

LGE/MMC 算法在降维后的低维空间里尽可能地保持原空间中各样本之间邻近关系,即在低维特征空间里最小化局部方差,使原本邻近的样本仍然保持紧凑关系;同时在降维后的低维空间里尽可能地保持原空间中各样本之间的非邻近关系,即在低维特征空间里最大化非局部方差,使原本远离的样本仍然保持疏远关系。

因此可以考虑用多目标函数解决最优问题,即

$$\begin{cases} \min \operatorname{tr}\{A^T X M X^T A\} \\ \max \operatorname{tr}\{A^T X L^p X^T A\} \\ \text{s. t. } A^T X X^T A = I. \end{cases} \quad (7)$$

为了避免类似 LDA 中出现的小样本问题,本文采用散度差分的形式构造目标函数。所以式(7)可以化为单一目标函数

$$\begin{aligned} \min \operatorname{tr}\{A^T X(M - \mu L^p)X^T A\} \\ \text{s. t. } A^T X X^T A = I. \end{aligned} \quad (8)$$

其中 μ 为平衡 M 和 L^p 参数。那么式(8)的最小化问题可以利用 Lagrange 乘数法来解决,即

$$L(A, \lambda) = \{A^T X(M - \mu L^p)X^T A - \lambda(A^T X X^T A - I)\}.$$

令 $\frac{\partial L(A, \lambda)}{\partial A} = 0$, 得到 $X(M - \mu L^p)X^T A =$

$\lambda X X^T A$; 其中, λ 是 $X(M - \mu L^p)X^T$ 和 $X X^T$ 的特征值, a_i 是对应的特征向量。所以,当 $A_{\text{LGE/MMC}} = \{a_1, a_2, \dots, a_d\}$ 由特征方程式(8)分解的前 d 个最小特征向量组成时,目标函数最小。

3 实验结果与分析

为了验证本文提出的 LGE/MMC 算法在人脸识别中的有效性,我们在 ORL, Yale 和 AR 人脸图像库上进行了充分的实验,并比较了 LGE/MMC 算法与 LDA^[6], MMC^[21], LLE^[89], DLA^[22-23] 和 LLE+LDA^[16-17] 算法的分类识别性能。所有的算法均采用欧氏距离和最近邻分类器。在实验中,为了快速得到结果,每种算法都用 PCA 作预处理。此时,本文保持约 95% 的图像能量。实验环境如下: Dell PC, CPU 为 Inter Athlon(tm) 64 Processor, 1 024 MB 内存, Matlab 7. 01。

3.1 人脸图像库及实验设计

ORL 标准人脸图像库^①由 40 人,每人 10 幅图像组成,其中有些图像是拍摄于不同时期的;人的脸部表情和脸部细节有着不同程度的变化,比如笑或不笑,眼睛或睁或闭,戴或不戴眼镜;人脸姿态也有

相当程度的变化,深度旋转和平面旋转可达 20° ;人脸的尺度也有多达 10% 的变化。实验中,图像被处理成 56×46 维的形式。实验中本文随机选取前 $l(l=2, 3, 4, 5, 6)$ 幅图像训练,剩余 $10-l$ 图像用于测试。对于每次选取的 l 幅图像,都进行 50 次实验,最后的结果是 50 次的平均结果。

Yale 人脸图像库^②中包括了 15 个人的 165 幅灰度人脸图像,每个人由 11 幅照片构成,这些照片在不同的表情和光照等条件下拍摄。实验中,图像被处理成 50×40 维的形式,同时,随机选取前 $l(l=2, 3, 4, 5, 6)$ 幅图像训练,剩余 $11-l$ 图像用于测试。对于每次选取 l 幅图像,也是进行 50 次实验,最后的结果是 50 次的平均结果。

AR 人脸图像库^③包含 126 个人(70 位男性,56 位女性)的 4000 多幅彩色人脸图像,这些图像由不同光照、不同表情和不同的遮挡情况下的正面人脸图像组成,大部分人的图像是在相隔 2 周的时间下拍摄的 2 个像集,每个像集包含 13 幅彩色图像和 120 个人(65 位男性,55 位女性)。实验中采用了这 120 个人的图像中没戴围巾的人脸图像,每人 20 幅,共计 2400 幅人脸图像。本文手动裁剪下了这些图像,并归一到 50×40 维的灰度图像。实验中随机选取前 $l(l=2, 3, 4, 5, 6)$ 幅图像训练,剩余 $20-l$ 图像用于测试。对于每次选取 l 幅图像,也是进行 10 次实验,最后的结果是 10 次的平均结果。图 1a~1c 分别是 3 个人脸图像库预处理后的图像示例。

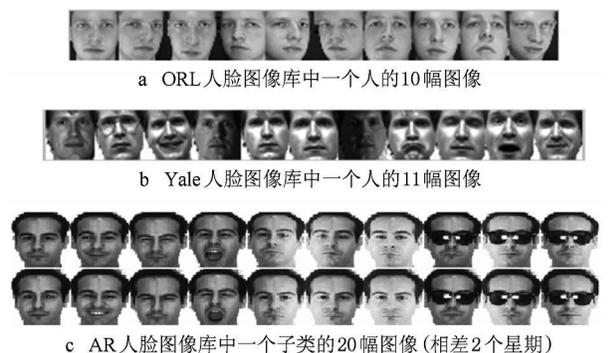


图 1 预处理后的图像示例

3.2 参数选择

在经典的特征抽取算法中,各种参数的选择一直是一个开放的问题。同样,LGE/MMC 算法的平衡参数 μ 以及类内近邻数 k_c 和类间近邻参数 k_p 对

① <http://www.uk.research.att.com/facedatabase.html>

② <http://www.cvc.yale.edu/projects/yalefaces/yalefaces.html>

③ http://colweb.ecn.purdue.edu/~aleix/aleix_face_DB.html

识别精度也有显著的影响. 本文设置类内近邻数 $k_c = l - 1$, 同时利用交叉验证的方法对该算法平衡参数 μ 参数和类间近邻参数 k_p 的进行选择. 本文在 Yale 人脸图像库中随机选择 $l (l = 2)$ 幅图像作为训练样本, 其余所有图像作为测试样本, 进行了 50 次重复实验. 图 2 a, 2b 给出了在平衡参数 μ 与类间近邻参数 k_p 的不同取值情况下的平均识别率, 可以看出, 平衡参数 μ 取 0.05~ 1 和类间近邻参数 k_p 取 4~

10 时, 平均识别率比较稳定, 且平衡参数 $\mu = 0.3$ 与类间近邻参数 $k_p = 4$ 时, 平均识别率达到最大值为 94.79. 由于不同的人脸库导致平衡参数 μ 与类间近邻参数 k_p 的取值不同, 本文不能保证平衡参数 $\mu = 0.3$ 与类间近邻参数 $k_p = 4$ 在其他人脸库做实验时能达到最大平均识别率. 因此, 在后续的实验中, 本文用平衡参数 μ 取 0.05~ 1, 间隔 0.05; 类间近邻参数 k_p 取 4~ 10, 间隔 1 做交叉实验.

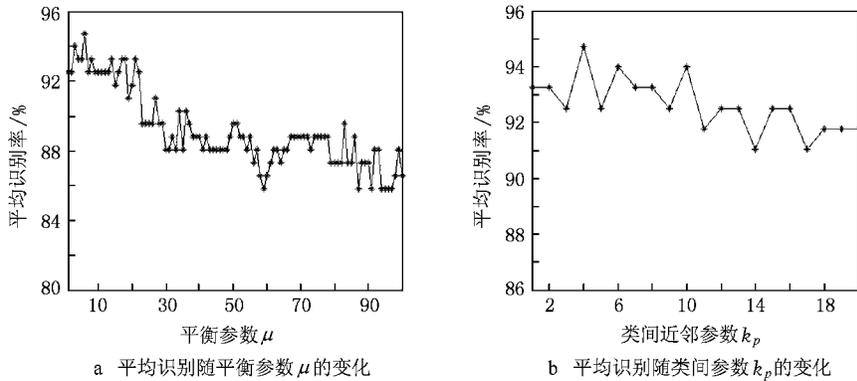


图 2 LGE/MMC 算法在 Yale 人脸图像库上识别精度随 μ 和 k_p 值的变化

3.3 识别实验与分析

3.3.1 平均识别率与特征维度的关系

本实验的目的是考察 LGE/MMC 算法平均识

别率随特征维度的变化关系. 本文在 ORL, Yale 和 AR 人脸图像库上进行了实验, 并分别随机选择各图像库中前 4, 6, 5 幅图像作为训练样本, 该库的其他

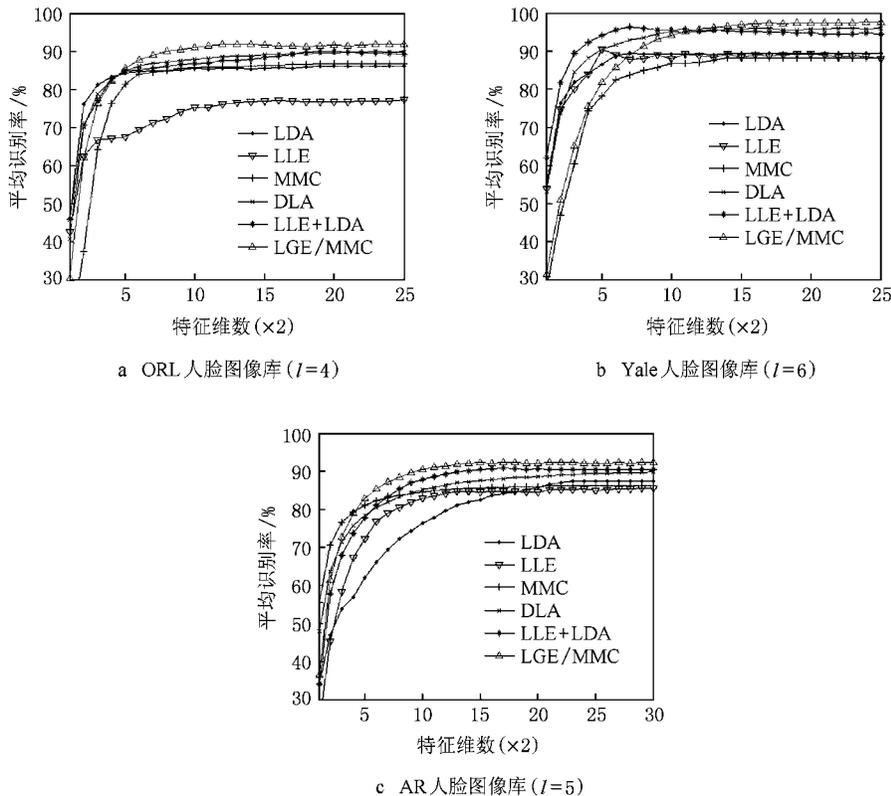


图 3 LGE/MMC 算法平均识别率随特征维度的变化情况

所有图像作为测试样本;相应各库中其余图像作为测试样本.其中,ORL和Yale人脸库图像进行50次重复实验,AR人脸图像库进行10次重复实验,结果分别如图3所示.由图3本文可以得到以下结论:

1) LGE/MMC算法随特征维数增大平均识别率也一直增大,且在维数比较高时,该算法的平均识别率优于其他5种经典算法的平均识别率.

2) LDA和LLE+LDA算法在特征维数比较低时,平均识别率高于LGE/MMC算法的平均识别率.这是由于LDA算法的最优鉴别维数不超过 $c-1$ (c 为类别数)时,识别性能最好.LDA算法的平均识别率和MMC算法的平均识别率相差不大.可以看出,MMC算法过程与LDA算法过程本质一样,只是MMC算法避免了LDA算法的奇异性和矩阵的翻转.

3) LLE算法的平均识别率比较低,说明LLE算法不适用于对数据的分类.LLE+LDA算法的平均识别率高于LLE算法平均识别率是由于LDA算法有很强的数据分类功能.

4) 多数情况下,有监督学习算法LDA,MMC和LLE+LDA的平均识别率优于无监督学习算法LLE的平均识别率.与LDA,MMC和LLE+LDA算法的平均识别率相比,LGE/MMC算法的平均识别率最好.LGE/MMC算法远远优于LLE算法是由于该算法既考虑类内数据的分布,同时考虑类间的数据分布.

3.3.2 人脸识别性能比较

本节比较在不同的训练样本下不同的最大算法的平均识别率变化.我们分别在ORL,Yale和AR人脸图像库上对比LGE/MMC算法与几种经典算法的识别性能.在每个库上进行实验时,首先用PCA算法对人脸图像进行预处理,然后利用各种特征提取算法提取特征,最后利用最近邻分类器完成分类识别.其中在ORL和Yale人脸图像库实验均重复进行了50次,在AR人脸库重复进行了10次.表1~3分别给出了各种特征提取方法分别在ORL,Yale和AR人脸图像库上的最大平均识别率(括号中数值为特征维度).

表1 ORL人脸库上不同算法的最大平均识别率

%

算法	训练样本集				
	2	3	4	5	6
LDA	77.42(38)	85.09(38)	86.17(38)	87.23(38)	89.38(38)
LLE	70.60(44)	73.39(36)	77.46(50)	80.00(28)	89.99(50)
MMC	76.78(40)	84.44(40)	86.85(38)	88.32(38)	91.66(40)
DLA	77.86(36)	86.27(36)	89.98(46)	92.71(38)	94.39(38)
LLE+LDA	74.60(36)	87.07(40)	90.13(40)	90.40(42)	96.35(18)
LGE/MMC	77.41(40)	87.41(50)	91.98(50)	95.62(50)	97.25(50)

表2 Yale人脸库上不同算法的最大平均识别率

%

算法	训练样本集				
	2	3	4	5	6
LDA	81.93(14)	85.61(14)	88.30(14)	88.84(14)	89.36(14)
LLE	84.93(17)	84.17(11)	86.65(9)	90.00(11)	90.53(10)
MMC	81.29(21)	83.72(14)	86.99(14)	87.20(14)	88.29(14)
DLA	88.49(28)	91.47(30)	92.37(30)	95.96(28)	96.01(28)
LLE+LDA	89.54(34)	93.20(28)	93.85(16)	96.55(14)	96.45(14)
LGE/MMC	94.79(48)	95.37(28)	94.90(50)	96.58(50)	97.55(48)

表 3 AR 人脸库上不同算法的最大平均识别率

算法	训练样本集					%
	2	3	4	5	6	
LDA	72.21(115)	76.34(115)	83.84(115)	87.45(115)	88.33(115)	
LLE	71.29(135)	75.47(120)	84.84(120)	85.54(135)	87.38(135)	
MMC	68.54(120)	76.03(120)	83.60(140)	86.21(120)	88.68(120)	
DLA	70.79(150)	79.83(150)	88.87(150)	89.84(150)	92.58(150)	
LLE+LDA	70.58(140)	80.12(120)	89.53(120)	90.58(125)	93.50(120)	
LGE/MMC	72.98(105)	81.78(80)	91.35(140)	92.31(75)	96.40(85)	

从表 1~3 可以看出, LGE/MMC 算法在 ORL, Yale 和 AR 人脸图像库上都取得了非常好的识别效果. 由表 1~3 可以得到以下结论:

1) 表 1 中, LGE/MMC 算法的最大平均识别率高于其他几种经典算法, 特别是在大样本情况下效果比较明显. 这是由于在样本稀疏时, LGE/MMC 算法不能准确反映样本在原始空间的流形分布.

2) 表 2 中, LGE/MMC 算法的最大平均识别率高于其他几种经典算法. 但是随着样本数增加, 该算法最大平均识别率变化不是很明显, 这是由于 Yale 人脸图像库上受光照的影响很大.

3) 表 3 中, 几种经典的算法在小规模的人脸数据库上可以获得较好的识别结果, 但对于大规模数据库如 AR 人脸图像库, 这些算法的识别性能还有待进一步提高, 而 LGE/MMC 算法比其他几种算法有明显的优势.

4 结 语

本文在 LLE 和 MMC 算法基础上提出 LGE/MMC 算法, 并给出了其推导过程. 该算法的目的是在保持近邻的前提下, 利用 MMC 来构造类内紧致图和类间惩罚图, 使用经过调整的平衡参数 μ , 类内近邻数 k_c 和类间近邻参数 k_p , 来保证在各向量间相互正交的基础上进行局部图嵌入, 从而更有效地提取出人脸非线性局部结构. 在 ORL, Yale 和 AR 3 种人脸图像库上的实验也表明, 该算法具有更好的局部保持性能, 且运用在人脸识别上效果优于其他几种经典子空间学习方法. 值得指出的是, 由于平衡参数 μ , 类内近邻数 k_c 和类间近邻参数 k_p 的选择至今仍然没有一个确定的理论依据, 因此如何在理论上找到这些最优参数来更有效地在子空间中发掘人脸图像中非线性高维数据本质的、内在的结构, 将是我们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 Surveys*, 2003, 35(4): 399-458
- [2] Chellappa R, Wilson C L, Sirohey S. Human and machine recognition of faces: a survey [J]. *Proceedings of the IEEE*, 1995, 83(5): 705-741
- [3] Liu Q S, Lu H Q, Ma S D. A survey: subspace analysis for face recognition [J]. *Acta Automatica Sinica*, 2003, 29(6): 900-911
- [4] Lin Yusheng, Zheng Yujie, Yang Jingyu. An improved kernel feature extraction method and its application to face recognition [J]. *Journal of Computer Aided Design & Computer Graphics*, 2008, 20(1): 61-65 (in Chinese) (林宇生, 郑宇杰, 杨静宇. 一种改进的核特征抽取方法及其在人脸识别中的应用 [J]. *计算机辅助设计与图形学学报*, 2008, 20(1): 61-65)
- [5] Turk M, Pentland A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86
- [6] Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7): 711-720
- [7] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500): 2319-2323
- [8] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500): 2323-2326
- [9] Saul L K, Roweis S T. Think globally, fit locally: unsupervised learning of low dimensional manifolds [J]. *The Journal of Machine Learning Research*, 2003, 4: 119-155
- [10] Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering [J]. *Advances in Neural Information Processing System*, 2002, 14(1/2): 585-591
- [11] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6): 1373-1396

- [12] de Ridder D, Duin R P W. Locally linear embedding for classification [D]. Delft: Delft University of Technology, 2002
- [13] de Ridder D, Kouropteva O, Okun O, *et al.* Supervised locally linear embedding [M] //Lecture Notes in Computer Science. Heidelberg: Springer, 2003, 2714: 333-341
- [14] Bai X M, Yin B C, Shi Q, *et al.* Face recognition based on supervised locally linear embedding method [J]. Journal of Information and Computation Science, 2005, 2(4): 641-646
- [15] Kouropteva O, Okun O, Pietikainen M. Supervised locally linear embedding algorithm for pattern recognition [M] //Lecture Notes in Computer Science. Heidelberg: Springer, 2003, 2652: 386-394
- [16] Zhang J P, Shen H X, Zhou Z H. Unified locally linear embedding and linear discriminant analysis algorithm for face recognition [M] //Lecture Notes in Computer Science. Heidelberg: Springer, 2005, 3338: 1-16
- [17] Zhang J P, He L, Zhou Z H. Ensemble based discriminant manifold learning for face recognition [M] //Lecture Notes in Computer Science. Heidelberg: Springer, 2006, 4221: 29-38
- [18] 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
- [19] He X F, Cai D, Yan S C, *et al.* Neighborhood preserving embedding [C] //Proceedings of the 10th IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2005: 1208-1213
- [20] Keinosuke F. Introduction to statistical pattern recognition [M]. 2nd ed. Washington D C: Academic Press, 1991
- [21] Li H F, Jiang T, Zhang K S. Efficient and robust feature extraction by maximum margin criterion [J]. IEEE Transactions on Neural Networks, 2006, 17(1): 1157-1165
- [22] Zhang T H, Tao D C, Yang J. Discriminative locality alignment [M] //Lecture Notes in Computer Science. Heidelberg: Springer, 2008, 5302: 725-738
- [23] Zhang T H, Tao D C, Li X L, *et al.* Patch alignment for dimensionality reduction [J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 21(9): 1299-1313