

一种人脸图像特征提取的局部和整体间距嵌入方法

杜海顺 李玉玲 侯彦东 金 勇

(河南大学图像处理与模式识别研究所 开封 475004)

摘 要 针对边界 Fisher 分析(MFA)构建的惩罚图没有充分描述类间数据分离度的缺点,提出一种局部和整体间距嵌入(LGME)特征提取方法。该方法在构建惩罚图时采用了全部的不同类样本数据对,并适当地强调了间距较小的不同类样本数据对的作用。与 MFA 相比, LGME 同时使用类间数据的局部和整体间距信息,对类间数据分离度进行了充分描述,从而使其提取的数据特征具有更强的判别力。实验结果表明, LGME 方法提取的人脸图像特征在用于人脸识别时,具有较高的识别率,且更具鲁棒性。

关键词 人脸识别,特征提取,边界 Fisher 分析(MFA),局部和整体间距嵌入(LGME)

中图法分类号 TP391.4 文献标识码 A

Local and Global Margin Embedding Method for Feature Extraction of Face Image

DU Hai-shun LI Yu-ling HOU Yan-dong JIN Yong

(Institute of Image Processing and Pattern Recognition, Henan University, Kaifeng 475004, China)

Abstract To overcome the disadvantage that the penalty graph constructed by marginal Fisher analysis (MFA) can't sufficiently describe interclass separability, this paper proposed a novel feature extraction method, called local and global margin embedding (LGME). In LGME, all interclass data pairs are used to construct penalty graph, whereas the importance of limited interclass data pairs with minimal margins is emphasized properly. Compared with MFA, LGME simultaneously uses local and global interclass margin to characterize interclass separability, so the data features extracted by LGME have more discriminative power. The experimental results show that the face image features extracted by LGME for face recognition have higher recognition rate and more robust.

Keywords Face recognition, Feature extraction, Marginal Fisher analysis (MFA), Local and global margin embedding (LGME)

1 引言

如何有效地提取人脸图像的特征,是人脸识别中的一个关键问题。人脸图像特征提取常采用将人脸图像嵌入到一个低维子空间的方法来实现。在过去几十年里,涌现了很多子空间学习方法,其中最具有代表性的是主成分分析(PCA)^[1]和线性判别分析(LDA)^[2]。

近年来的研究表明,人脸图像可能在一个非线性流形上^[3-5]。因此,国内外许多学者对流形学习表现出了很大的关注,提出的距映射(Isomap)^[6]、局部线性嵌入(LLE)^[4]、拉普拉斯特征映射(laplacian eigenmap)^[6]和局部保持投影(LPP)^[7]等流形学习方法,都能学习隐藏在高维数据空间中的低维流形结构。然而,这些方法都力图在低维子空间中保持高维数据空间的局部流形结构,而忽视了对高维数据空间中判别信息的学习。因此,将它们提取的人脸图像特征用于分类识别,效果并不理想^[8,9]。

为了解决这一问题,国内外学者提出了一些有监督的流形学习方法,如局部判别嵌入(LDE)^[10]、边界 Fisher 分析(MFA)^[11]等。这些方法在学习低维流形结构的同时,进一步

强调了判别信息的作用,从而使它们提取的特征更有利于数据的分类识别。近年来, Yan 等学者提出了一种图嵌入框架^[11],将上述的有监督流形学习方法和许多流行的子空间学习方法都纳入到该框架中。另外,即使是近两年提出的 patch-based 方法^[12]和一些有监督流形学习方法^[13-15],其仍可以被纳入到图嵌入框架中。

基于图嵌入框架的 MFA 通过构建固有关系图和惩罚图来描述类内数据的紧密度和类间数据的分离度,并基于此提出了边界 Fisher 准则^[11]。文献[11]的实验结果表明,将 MFA 提取的人脸图像特征用于分类识别时,具有较高的人脸识别率。然而,由于 MFA 只采用了较少的不同类样本数据对来构建惩罚图,因此其构建的惩罚图仅使用了类间数据的局部间距信息来描述类间数据的分离度。显然,它对类间数据分离度的描述是不充分的。为了解决这一问题,本文提出了一种局部和整体间距嵌入(LGME)特征提取方法。该方法在构建惩罚图时,采用了全部的不同类样本数据对,并适当地强调了间距较小的不同类样本数据对的作用。与 MFA 相比, LGME 同时使用类间数据的局部和整体间距信息,对类间数据分离度进行了充分描述,从而使得嵌入到 LGME 子空

间的不同类数据之间可以很好地分离。

2 边界 Fisher 分析(MFA)概述

设 $X = [x_1, x_2, \dots, x_n] \in R^{m \times N}$ 为训练样本集, 其中 $x_i \in R^m$, N 为训练样本个数, m 为训练样本的维数。训练样本 x_i 的类别标签记为 $c_i \in \{1, 2, \dots, N_c\}$, 其中 N_c 为训练样本的类别数。另外, 记第 c 类训练样本的序号集合为 π_c , 第 c 类训练样本个数为 n_c 。MFA 通过构建固有关系图 G^c 和惩罚图 G^p 来描述类内数据的紧密度和类间数据的分离度。具体地, 对任一投影变换矩阵 P , 基于固有关系图 G^c , 类内数据紧密度定义为^[11]:

$$\begin{aligned} S_c &= \sum_{i \in N_{k_1}(j)} \sum_{j \in N_{k_1}(i)} \|P^T x_i - P^T x_j\|^2 \\ &= 2\text{tr}(P^T X(D-W)XP^T) \\ &= 2\text{tr}(P^T XLXP^T) \\ W_{ij} &= \begin{cases} 1, & \text{if } i \in N_{k_1}(j) \text{ or } j \in N_{k_1}(i) \\ 0, & \text{otherwise} \end{cases} \end{aligned} \quad (1)$$

式中, $N_{k_1}(i)$ 为与训练样本 x_i 同类的 k_1 个最近邻样本序号集合; D 为对角阵, $D_{ii} = \sum_j W_{ij}$; $L = D - W$ 为拉普拉斯矩阵。

基于惩罚图 G^p , 类间数据分离度定义为^[11]:

$$\begin{aligned} S_p &= \sum_{(i,j) \in P_{k_2}(c_i) \text{ or } (i,j) \in P_{k_2}(c_j)} \|P^T x_i - P^T x_j\|^2 \\ &= 2\text{tr}(P^T X(D^p - W^p)XP^T) \\ &= 2\text{tr}(P^T XL^pXP^T) \\ W_{ij}^p &= \begin{cases} 1, & \text{if } (i,j) \in P_{k_2}(c_i) \text{ or } (i,j) \in P_{k_2}(c_j) \\ 0, & \text{otherwise} \end{cases} \end{aligned} \quad (2)$$

式中, $P_{k_2}(c)$ 是样本对序号集合 $\{(i,j), i \in \pi_c, j \notin \pi_c\}$ 的 k_2 个最近邻样本对序号子集; D^p 为对角阵, $D_{ij}^p = \sum_j W_{ij}^p$; $L^p = D^p - W^p$ 为拉普拉斯矩阵。

根据类内数据紧密度和类间数据分离度的定义, MFA 给出如下的边界 Fisher 准则函数^[11]:

$$J = \arg \min_P \frac{\text{tr}(P^T XLXP^T)}{\text{tr}(P^T XL^pXP^T)} \quad (3)$$

对该准则函数求解, 可得 MFA 投影变换矩阵 P 。对任一数据 x , 通过如下线性变换, 可得其在低维 MFA 子空间的数据表示:

$$y = P^T x \quad (4)$$

3 局部和整体间距嵌入方法

3.1 基本思想

由于 MFA 仅采用了较少的不同类样本数据对来构建惩罚图, 因此使得它对类间数据分离度的描述是不充分的。为了解决这一问题, 本文提出一种局部和整体间距嵌入 (LGME) 的特征提取方法。该方法同样通过构建固有关系图 G^c 和惩罚图 G^p , 来分别描述类内数据的紧密度和类间数据的分离度。然而, LGME 在构建惩罚图时, 采用了全部的不同类样本数据对, 并适当地强调了间距较小的不同类样本数据对的作用。

假设 $X = [x_1, x_2, \dots, x_n] \in R^{m \times N}$ 为训练样本集, 其中 $x_i \in R^m$, N 为训练样本个数, m 为训练样本的维数。训练样本 x_i 的类别标签记为 $c_i \in \{1, 2, \dots, N_c\}$, 其中 N_c 为训练样本的类别数。令训练样本集 X 中的每个样本对应 LGME 构建的固有关系图 G^c 中的每个节点, 即样本 x_i 对应节点 i 。 G^c 中节点间的权重为:

$$W_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2/t), & \text{if } i \in N_{k_1}(j) \text{ or } j \in N_{k_1}(i) \\ 0, & \text{otherwise} \end{cases} \quad (5)$$

式中, $N_{k_1}(i)$ 为与训练样本 x_i 同类的 k_1 个最近邻样本序号集合。

同样地, 令训练样本集 X 中的每个样本对应 LGME 构建的惩罚图 G^p 中的每个节点。 G^p 中节点间的权重为:

$$W_{ij}^p = \begin{cases} \exp(-\|x_i - x_j\|^2/t), & \text{if } c_i \neq c_j \text{ and } j \notin N_{k_2}'(i) \text{ and } i \notin N_{k_2}'(j) \\ \lambda \exp(-\|x_i - x_j\|^2/t), & \text{if } j \in N_{k_2}'(i) \text{ or } i \in N_{k_2}'(j) \\ 0, & \text{otherwise} \end{cases} \quad (6)$$

式中, $N_{k_2}'(i)$ 为与训练样本 x_i 不同类的 k_2 个最近邻样本序号集合; λ 为强调局部间距作用的参数, $\lambda > 1$ 。

给定任一嵌入向量 p , 基于固有关系图 G^c 的权重矩阵 W , 训练样本集 X 嵌入到向量 p 后的类内数据紧密度定义为:

$$\begin{aligned} S_c &= \frac{1}{2} \sum_{ij} W_{ij} (p^T x_i - p^T x_j)^2 \\ &= \sum_{ij} p^T x_i W_{ij} x_j^T p - \sum_{ij} p^T x_i W_{ij} x_j^T p \\ &= \sum_{ij} p^T x_i D_{ii} x_i^T p - \sum_{ij} p^T x_i W_{ij} x_j^T p \\ &= p^T XDX^T p - p^T XWX^T p \\ &= p^T X(D-W)X^T p \\ &= p^T XLX^T p \end{aligned} \quad (7)$$

式中, D 为对角阵, $D_{ii} = \sum_j W_{ij}$; $L = D - W$ 为固有关系图 G^c 的拉普拉斯矩阵。

基于惩罚图 G^p 的权重矩阵 W^p , 训练样本集 X 嵌入到向量 p 后的类间数据分离度定义为:

$$\begin{aligned} S_p &= \frac{1}{2} \sum_{ij} W_{ij}^p (p^T x_i - p^T x_j)^2 \\ &= \sum_{ij} p^T x_i W_{ij}^p x_j^T p - \sum_{ij} p^T x_i W_{ij}^p x_j^T p \\ &= \sum_{ij} p^T x_i D_{ii}^p x_i^T p - \sum_{ij} p^T x_i W_{ij}^p x_j^T p \\ &= p^T XD^pX^T p - p^T XW^pX^T p \\ &= p^T X(D^p - W^p)X^T p \\ &= p^T XL^pX^T p \end{aligned} \quad (8)$$

式中, D^p 为对角阵, $D_{ii}^p = \sum_j W_{ij}^p$; $L^p = D^p - W^p$ 为惩罚图 G^p 的拉普拉斯矩阵。

根据 LGME 的类内数据紧密度和类间数据分离度的定义, 给出其目标函数如下:

$$J(p) = \frac{S_p}{S_c} = \frac{p^T XL^pX^T p}{p^T XLX^T p} \quad (9)$$

显而易见, 矩阵 XL^pX^T 和 XLX^T 都是对称半正定阵。通过简单的数学推导, 求解目标函数式(9)可以转变成求解如下广义特征值问题:

$$XL^pX^T p = \lambda XLX^T p \quad (10)$$

明显地, 式(10)最大特征值对应的特征向量就是使目标函数式(9)最大的最优嵌入向量 p 。然而, 当样本类别数较多时, 对分类来说, 一个最优嵌入向量是不够的。因此, 必须得到一组最大化目标函数式(9)的最优嵌入向量组。设 $p_0, p_1, \dots, p_{d-1}$ 是式(10)前 d 个最大特征值对应的特征向量, 则 p_0 ,

$p_1, \dots, p_{d-1}$ 就是最大化目标函数式(9)的最优嵌入向量组。令 $P = [p_0, p_1, \dots, p_{d-1}]$, 则 P 为 LGME 嵌入变换矩阵。

3.2 LGME 方法提取人脸图像特征

LGME 方法提取人脸图像特征的过程如下:

(1) 首先将原始人脸图像数据集 X 嵌入到 PCA 子空间。需要指出的是, 在以下步骤中仍将嵌入到 PCA 子空间的人脸图像记为 x 。令 P_{PCA} 表示 PCA 的嵌入变换矩阵。

(2) 构建 LGME 的固有关图 G 和惩罚图 G^p , 并分别采用式(5)和式(6)来计算它们的权重矩阵 W 和 W^p , 进一步计算类内数据紧密度 S_c 和类间数据分离度 S_p 。根据 S_c 和 S_p , 得到 LGME 的目标函数式(9)。

(3) 通过求解式(10)的广义特征值问题, 得到 LGME 嵌入变换矩阵 P_{LGME} 。最终, 原始人脸图像嵌入到 LGME 子空间的嵌入变换矩阵为 $P = P_{PCA} P_{LGME}$ 。

(4) 对原始人脸图像 $x \in R^m$ 采用嵌入变换矩阵 P 进行嵌入变换, 可得到其在 LGME 子空间的低维特征 $y \in R^d$: $y = P^T x$ 。

4 实验

为了验证 LGME 方法的有效性, 本文将 LGME 与 PCA、LDA、LPP、MFA 等方法提取的人脸图像特征分别用于分类识别, 并比较它们的识别性能。

4.1 人脸数据库介绍

实验中, 本文采用 ORL 和 Yale 人脸图像数据库来验证 LGME 方法的性能。ORL 人脸数据库是由 40 人的 400 张人脸图像组成, 其中每人 10 张图像, 每张图像的大小均为 190×92 像素。该数据库中的人脸图像表情、脸部细节变换比较大, 并且拍摄视觉变化也有一定程度的变化。Yale 人脸数据库由 15 人的 165 张人脸图像组成, 其中每人 11 张图像, 每张图像的大小为 243×320 像素。该数据库中的人脸图像光照、表情以及拍摄角度都有较大程度的变化。

为了计算的方便性, 本文对两个人脸数据库中的每张图像都以眼睛为中心进行了适当剪切处理, 并将其大小缩放为 32×32 像素。两个数据库中的部分人脸图像如图 1 和图 2 所示。



图 1 ORL 人脸数据库中部分人脸图像



图 2 Yale 人脸数据中部分人脸图像

表 1 ORL 和 Yale 数据库上的最高人脸识别率及其相应特征向量维数比较

特征提取方法	ORL				Yale			
	3	4	5	6	3	4	5	6
PCA	77.11(80)	84.29(51)	89.00(148)	91.56(163)	49.33(28)	54.86(27)	58.22(31)	57.60(34)
LDA	86.20(38)	92.00(38)	93.95(36)	95.56(39)	59.67(12)	66.86(13)	73.19(14)	79.33(14)
LPP	69.93(60)	72.75(71)	75.30(56)	80.06(97)	41.67(23)	43.71(30)	47.00(38)	45.20(45)
MFA	85.75(37)	91.71(43)	94.15(55)	96.06(49)	61.25(13)	67.14(14)	74.67(16)	79.07(17)
LGME	88.46(48)	94.25(76)	96.60(89)	97.88(120)	62.75(13)	69.24(14)	76.22(16)	81.20(23)

注: 括号中的数字代表该识别率所对应的特征向量维数

4.2 实验方案及结果分析

实验时, 在每个人脸数据库中每人随机选取 k ($k=3, 4, 5, 6$) 张人脸图像组成训练样本集, 其余人脸图像组成测试样本集。本文分别采用 PCA、LDA、LPP、MFA 和 LGME 方法提取人脸图像特征, 并采用最近邻分类器进行分类识别。值得一提的是, 在采用 LDA、LPP、MFA 和 LGME 方法提取人脸图像特征之前, 需要预先对原始人脸图像进行 PCA 处理。在本文进行 PCA 预处理后, 人脸图像数据的维数降为 $N-N_c$, 其中 N 为训练样本个数, N_c 为训练样本的类别数。为了避免选择样本的随机性, 对任意每人训练样本数 k , 重复上述实验过程 10 次, 最后取 10 次实验的平均识别率作为最终识别率。实验结果见图 3、图 4 和表 1。




图 3 ORL 数据库上每人 3~6 幅图像构成训练样本时的人脸识别率曲线




图 4 Yale 数据库上每人 3~6 幅图像构成训练样本时的人脸识别率曲线

图 3 和图 4 分别给出了 ORL 和 Yale 人脸数据库上,在每类不同训练样本数的情况下,LGME 与其它 4 种方法提取的人脸图像特征用于人脸识别时随特征维数变化的识别率曲线比较。表 1 给出了 ORL 和 Yale 人脸数据库上,在每类不同训练样本数的情况下,LGME 与其它 4 种方法提取的人脸图像特征用于人脸识别时的最高识别率及相应特征维数进行对比。由图 3、图 4 和表 1 可以看出,相比于 PCA、LDA、LPP、MFA 等特征提取方法,LGME 方法提取的人脸图像特征在用于人脸识别时,具有较高的识别率。这很容易理解,因为 PCA 主要保持了数据空间的全局结构信息;LDA 主要保持了数据空间的判别信息;LPP 主要保持了数据空间的流形结构信息;MFA 通过构建固有关系图和惩罚图来描述类内数据的紧密度和类间数据的分离度,使得提取的特征在保持数据空间的流形结构信息的同时,具有较强的判别力;而 LGME 同时使用类间数据的局部和整体间距信息,对类间数据分离度进行了充分描述,从而使得 LGME 方法提取的数据特征具有更强的判别力。

结束语 本文基于图嵌入框架,在构建惩罚图时采用全部的不同类样本数据对,并适当地强调间距较小的不同类样本数据对的作用,提出了一种局部和整体间距嵌入 (LGME) 方法,并将其用于提取人脸图像特征。与 MFA 不同,由于 LGME 同时使用类间数据的局部和整体间距信息,对类间数据分离度进行了充分的描述,使得 LGME 方法提取的数据特征具有更强的判别力。在 ORL 和 Yale 人脸库上的实验结果表明,与 PCA、LDA、LPP、MFA 等特征提取方法相比,本文提出的 LGME 方法提取的人脸图像特征在用于人脸识别时,具有较高的识别率,且更具鲁棒性。

参考文献

- [1] Turk M, Pentland A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86
- [2] 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
- [3] Tenenbaum J B, Silva V D, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(12): 2319-2322
- [4] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(12): 2323-2326
- [5] Shashua A, Levin A, Avidan S. Manifold pursuit: A new approach to appearance based recognition [C] // *Proceedings of 16th International Conference on Pattern Recognition*. Quebec City, Canada, 2002, 3: 590-594
- [6] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. *Neural Computation*, 2003, 15(6): 1737-1396
- [7] He X F, Niyogi P. Locality preserving projections [C] // *Proceedings of Neural Information Processing System*. 2003: 153-160
- [8] Gui J, Jia W, Zhu L, et al. Locality preserving discriminant projections for face and palmprint recognition [J]. *Neurocomputing*, 2010, 73(13-15): 2696-2707
- [9] Zhang L M, Qiao L S, Chen S C. Graph-optimized locality preserving projections [J]. *Pattern Recognition*, 2010, 43(6): 1993-2002
- [10] Chen H T, Chang H W, Liu T L. Local discriminant embedding and its variants [C] // *Proceedings of 2005 International Conference on Computer Vision and Pattern Recognition*. San Diego, USA, 2005(2): 846-853
- [11] Yan S C, Xu D, Zhang B Y, et al. Graph embedding and extensions: A general framework for dimensionality reduction [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(1): 40-51
- [12] Zhang T, Tao D, Li X, et al. Patch alignment for dimensionality reduction [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(9): 1299-1313
- [13] Zhang S W, Lei Y K, Wu Y H. Semi-supervised locally discriminant projection for classification and recognition [J]. *Knowledge-Based Systems*, 2011, 24(2): 341-346
- [14] Cheng M, Fang B, Tang Y Y, et al. Incremental embedding and learning in the local discriminant subspace with application to face recognition [J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 2010, 40(5): 580-591
- [15] Fang B, Cheng M, Tang Y Y, et al. Improving the discriminant ability of local margin based learning method by incorporating the global between-class separability criterion [J]. *Neurocomputing*, 2009, 73: 536-541
- [1] Turk M, Pentland A. Eigenfaces for recognition [J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86
- [2] 周子民, 朱再兴, 刘艳军, 等. 基于 Elman 神经网络的动力配煤发热量及着火温度的预测 [J]. *中南大学学报: 自然科学版*, 2011, 42(12): 3871-3875
- [3] El-Midany T T, El-Baz M A, Abd-Elwahed M S. A proposed framework for control chart pattern recognition in multivariate process using artificial neural networks [J]. *Expert Systems with Applications*, 2010, 37(1): 1035-1042
- [4] 吴伟, 李楠, 郭茂耘. 粗糙集及 PSO 优化 BP 网络的故障诊断研究 [J]. *计算机科学*, 2011, 38(11): 200-203
- [5] 满红, 邵诚. 基于 Hammerstein-wiener 模型的连续搅拌反应釜神经网络预测控制 [J]. *化工学报*, 2011, 62(8): 2275-2280
- [6] 胡包钢, 王泳, 杨双红, 等. 如何增加人工神经网络模型的透明度 [J]. *模式识别与人工智能*, 2007, 20(1): 72-83
- [7] Salari D, Daneshvar N, Aghazadeh F, et al. Application of artificial neural networks for modeling of the treatment of wastewater contaminated with methyl tert-butyl ether (MTBE) by UV/H₂O₂ process [J]. *Journal of Hazardous Materials*, 2005, B125(1): 205-210
- [8] Ozesmi S L, Ozesmi U. An artificial neural network approach to spatial habitat modeling with interspecific interaction [J]. *Ecological Modelling*, 1999, 116(1): 15-31
- [9] Gevrey M, Dimopoulos I, Lek S. Review and comparison of methods to study the contribution of variables in artificial neural network models [J]. *Ecological Modeling*, 2003, 160(1): 249-264
- [10] Olden J D, Joy M K, Death R G. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data [J]. *Ecological Modeling*, 2004, 178(1): 389-397
- [11] Olden J D, Jackson D A. Illuminating the "black box": a randomization approach for understanding variable contributions in artificial neural networks [J]. *Ecological Modeling*, 2002, 154(1): 135-150
- [12] 张昭昭, 乔俊飞, 韩红桂. 一种基于神经网络复杂度的修剪算法 [J]. *控制与决策*, 2010, 25(6): 821-830

(上接第 251 页)