

文章编号: 1001-0920(2012)05-0713-06

一种用于人脸识别的有监督核化多类多流形 ISOMAP 算法

程起才¹, 王洪元¹, 吴小俊², 冯 燕¹, 刘锁兰¹

(1. 常州大学 信息学院, 江苏 常州 213164; 2. 江南大学 物联网工程学院, 江苏 无锡 214000)

摘 要: 在核等测距映射 (kernel ISOMAP) 和多类多流形 ISOMAP 算法的基础上, 提出一种针对人脸识别任务的有监督核化多类多流形 ISOMAP 算法. 该算法保持了 kernel ISOMAP 算法的泛化特性, 同时又能完成分类任务, 解决了 ISOMAP-C 在对具有高维小样本特性的人脸数据集识别时, 所要调整的神经网络权值数目将随输入维度呈指数增长, 且易出现过拟合现象的问题. 在多种人脸数据集上的实验结果表明了该算法的有效性, 且对训练样本集的大小有较好的鲁棒性.

关键词: 核等测距映射; 多类多流形; 人脸识别; 小样本

中图分类号: TP311

文献标识码: A

A supervised kernelized multi-class multi-manifold ISOMAP algorithm for face recognition

CHENG Qi-cai¹, WANG Hong-yuan¹, WU Xiao-jun², FENG Yan¹, LIU Suo-lan¹

(1. School of Information, Changzhou University, Changzhou 213164, China; 2. School of Internet of Things Engineering, Jiangnan University, Wuxi 214000, China. Correspondent: WANG Hong-yuan, E-mail: hywang@jpu.edu.cn)

Abstract: Based on kernel ISOMAP and multi-class multi-manifold ISOMAP, supervised kernelized multi-class multi-manifold ISOMAP is proposed specially for the facial recognition, which not only preserves the generalization property of kernel ISOMAP, but also works in a supervised manner and solves the problem that the number of neural network's weights to be tuned increases exponentially with input dimension and easily occurs overfitting while using ISOMAP-C for face recognition. The experimental results on some face datasets show that the proposed method is effective and robust for the number of training sample.

Key words: kernel ISOMAP; multi-class multi-manifold; face recognition; small sample size

1 引 言

人脸识别是一种重要的生物特征识别技术, 与指纹、虹膜等生理特征识别技术相比, 具有直接、友好、方便的特点, 因此容易被用户所接受. 在过去几十年, 人们已经提出了很多人脸识别技术, 其中基于外观的人脸识别技术一直是最成功的技术之一.

就基于外观的人脸识别而言, 通常将一幅人脸图像变成高维空间中的一个向量 (如: 一幅 64×64 的图像, 将表示成 4096 维的高维向量), 而要识别的人脸图像集大小相对于维度而言是很小的, 造成人脸数据集在高维空间中分布非常稀疏, 因此直接进行信息处理会出现著名的“维数灾难”的问题. 为了解决该问题,

通常先采用降维的方法. 降维的方法包括线性降维和非线性降维. 针对人脸识别问题, 最著名的两个线性降维方法分别是基于主分量分析方法 (PCA)^[1] 的 Eigenfaces 方法和基于线性判别分析方法 (LDA)^[2] 的 Fisherfaces 方法. Eigenfaces 是将训练集通过 K-L (Karhunen-Loeve) 变换来获得一组特征脸, 这些特征脸可张成一个人脸空间, 对于线性嵌入的流形, PCA 方法能发现流形的内在维度并能产生其紧致表示. Fisherfaces 方法是在 Eigenfaces 方法的基础上进行了改进, 因为基于外观的人脸识别通常是典型的高维小样本问题, 大多数情况下类内散度矩阵是奇异的, 所以采取的方式是先通过 PCA 降维使类内散度矩

收稿日期: 2010-11-16; 修回日期: 2011-04-07.

基金项目: 国家自然科学基金项目(60973094, 61070121); 江苏省自然科学基金项目(BK2009538); 江苏省产学研前瞻性联合研究项目(BY2009117); 江苏省高校自然科学基金项目(09KJB520004).

作者简介: 程起才(1981—), 男, 讲师, 硕士, 从事机器学习与数据挖掘的研究; 王洪元(1960—), 男, 教授, 博士, 从事模式识别与智能系统的研究.

阵变为非奇异矩阵, 然后通过 LDA 作特征抽取和识别. 从大量的实验结果看, 通常认为 Fisherfaces 的效果会大大超过 Eigenfaces, 然而当每一类的训练样本集比较少时, Fisherfaces 的准确率大幅减少, 效果甚至比 Eigenfaces 差.

近几年, 大量的研究表明, 人脸可能位于一个非线性子流形上, 但 PCA 与 LDA 只能识别用欧氏距离度量的结构, 不能发现非线性数据集的内在结构. 然而一些经典的流形学习方法, 如: ISOMAP^[3], LLE^[4]等, 却能发现非线性流形的结构, 这是近几年来机器学习及其相关领域的研究热点. 就 ISOMAP 而言, 也有一些不足之处, 主要有: 1) ISOMAP 算法不能显式产生从高维空间到低维特征空间的映射函数, 从而对于一个新的样本点, 求出其对应的低维表示不得不重新运行一轮算法, 这明显是很耗时的; 2) ISOMAP 算法是无监督的, 在降维过程中没有利用标签, 不适合解决分类问题. 对此, 国内外学者提出了许多改进的 ISOMAP 算法. 其中: 针对第 1 个不足, 文献 [5] 提出了鲁棒的核 ISOMAP 算法^[5], 该算法在近似的测地线距离矩阵基础上构造核矩阵, 并通过加常数的技巧, 求得新样本点的嵌入; [6] 提出了一种增量 ISOMAP 算法, 该算法利用连通邻域图的方法, 实现了对未知样本点的低维嵌入, 但这些算法是无监督的. 针对第 2 个不足, [7] 提出了有监督 ISOMAP 算法^[7], 该算法在降维过程中利用了类标签, 解决了数据集的可视化和分类任务. 但正如其文末提到的, 该算法对数据簇分布较开的数据集是无效的, 相反 [8] 提出的多类多流形学习算法 (MCMM-ISOMAP) 能很好地解决数据簇分布较开的数据集可视化问题, 不过该算法也是无监督的. 在 MCMM-ISOMAP 算法的基础上, 本文利用类标签对数据集进行划分, 并通过 BP 神经网络和遗传算法近似构造高维原始空间到低维特征空间的映射函数, 提出解决分类任务的 ISOMAP 算法 (ISOMAP-C). 虽然 ISOMAP-C 方法在大部分 UCI 数据集上的分类效果较好, 但对于具有高维小样本特点的人脸数据集, BP 神经网络需要调整的权重数将随样本输入维度呈指数增加, 而且容易产生过拟合现象.

本文的创新点是: 在 MCMM-ISOMAP 算法的基础上, 结合 Kernel ISOMAP 的泛化特性, 提出一种有监督核化的多类多流形 ISOMAP 算法 (SK-MCMM-ISOMAP). 该算法既具有 Kernel ISOMAP 算法的泛化特性, 同时又能有效完成具有高维小样本特性的人脸数据集的分类任务, 避免 ISOMAP-C 算法中使用 BP 神经网络和遗传算法带来的以上问题.

2 MCMM-ISOMAP 算法概述

如果数据集抽样于多个类, 每个类对应一个潜在的低维流形, 则当这些类簇分散较开时, 应用 ISOMAP 算法可能会出现两个问题: 1) 若邻域参数选取较小时, 整个数据集上就会形成多个不连通的子邻域图; 2) 若邻域参数选取过大, 虽然在数据集上能构造唯一的邻域图, 但在每个类内可能出现了“短路边”, 从而破坏了数据集内部结构. MCMM-ISOMAP 算法能很好地解决该问题, 该算法是在每个类簇内部构造邻域图, 然后将类簇间欧氏距离最近的数据点互相设置为邻域点, 从而在整个数据集上构造了唯一的邻域图.

假设给定输入数据集为 $X = [x_1, x_2, \dots, x_N]$, $x_i \in R^n$, 这些元素抽样于 c 个类, 类簇间分隔较开. 很明显, 在选取合适的邻域参数后, 整个数据集上会产生 c 个子邻域图, 且每个类簇对应一个子邻域图, 记 X^i 为构成第 i 个子邻域图的数据集, $NE(x_i)$ 表示 x_i 的邻域点集合. 具体算法步骤如下:

Step 1: 选取合适的邻域参数 k 或 ε , 构造 c 个子邻域图, 若 x_i 是 x_j 的邻域点, 则用一条边连接 x_i 与 x_j , 且该边的权重为两点间的欧氏距离 $d(x_i, x_j)$.

Step 2: 求出各子邻域图顶点间相距最近的数据点对, 即

$$WM_i, WM_j = \arg \min_{w_i \in X^i, w_j \in X^j, 1 \leq i, j \leq c, i < j} (\|X^i - X^j\|). \quad (1)$$

其中: $WM_i \in X^i$, $WM_j \in X^j$.

Step 3: 设置 WM_i 与 WM_j 互为邻域点, 即对其各自的 $NE(WM_i)$ 和 $NE(WM_j)$ 分别更新为

$$NE(WM_i) \cup \{WM_j\}, \\ NE(WM_j) \cup \{WM_i\},$$

并且设这两点形成的边权重是 $d(WM_i, WM_j)$, 这样在整个数据集上就形成了唯一的邻域图 G .

Step 4: 通过 Floyd 算法或 Dijkstra 算法计算图 G 上任意点对 x_i 与 x_j 之间最短路径的长度 $d_G(x_i, x_j)$, 记矩阵 $D^2 = (d_G(x_i, x_j)^2)_{N \times N}$, 即矩阵 D 的平方是基于元素的平方.

Step 5: 构建数据集 X 的 m 维嵌入 $Y (m \ll n)$, 记 $K(D^2) = -\frac{1}{2}HD^2H$. 其中: $H = I - \frac{1}{N}ee^T$, $e = [1, 1, \dots, 1]^T \in R^N$, I 为单位阵. 假设 $K(D^2)$ 的前 m 个特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ 对应的特征向量分别为 v_1, v_2, \dots, v_m , 则 $Y = [y_1, y_2, \dots, y_N] = [\sqrt{\lambda_1}v_1, \sqrt{\lambda_2}v_2, \dots, \sqrt{\lambda_m}v_m]^T$.

然而, 该算法如同 ISOMAP 一样, 具有以下缺点: 1) 它是无监督的, 在降维过程中, 没有利用类

标签信息,所以该算法不适合分类任务;2)它没有显式地产生从 X 到 Y 的映射函数,即对于某个新的数据 x_{new} ,要得到其低维嵌入 y_{new} ,须将 X 更新为 $X \cup \{x_{\text{new}}\}$,然后重新运行上述5步得到 y_{new} ,很明显这是非常耗时的.虽然将ISOMAP应用于有监督范畴已经有文献报道,通常做法是将 (X, Y) 视为神经网络的输入输出对,通过神经网络来近似构建其映射关系,如ISOMAP-C算法.但若将此算法应用于人脸识别,则神经网络所需要调节的权重参数将随输入的维度呈指数增长,而且易产生过拟合问题,因为人脸数据集一般具有高维小样本的特性.本文将MCM-ISM-AP进行拓展,借鉴基于KPCA的Kernel ISOMAP思路,针对人脸数据集提出了用于人脸识别的SK-MCM-ISM-AP算法.

3 SK-MCM-ISM-AP 算法

假设原始高维有标签数据集为 $X = [(x_1, l_1), \dots, (x_N, l_N)]$,从模式分类的角度看,希望所给的数据集类间间隔越大越好.因此如果存在一个映射函数 $f: R^n \rightarrow R^m$ (通常 $m \ll n$),使得映射到低维特征空间的数据类间间隔大,类内距离小,则在这个低维特征空间中进行分类时,准确率将会得到提高.故SK-MCM-ISM-AP算法的目标有两个:1)在低维特征空间中使不同类间的数据分隔很开;2)通过显式映射函数获得测试数据集的低维特征空间表示.下面详细叙述如何完成这两个目标.

3.1 如何使属于不同类的数据在低维特征空间分隔较开

因为ISOMAP算法是等测距的,即要求高维空间数据点间的最短路径长度(测地线距离的近似)在低维空间中尽量保持,所以要达到属于不同类的数据在低维空间分隔较开的目的,实质上就是使高维原始空间中不同类数据间的最短路径长度增大.为此,在MCM-ISM-AP算法基础上进行改进,根据 X 的类标签信息,将 X 划分成 c 个子集 $X = X^1 \cup X^2 \cup \dots \cup X^c$;然后在第 i 类数据子集 X^i 上构造邻域图;最后用一条边连接类间相距最近的两个点,通过对该边的权重放大 γ ($\gamma > 1$)倍,使不同类的数据间的最短路径长度将会变大 γ 倍,从而使数据在低维特征空间中不同类的数据之间间隔变大.该过程具体如下:

Step 1: 根据类标签信息将 X 划分成 c 个子集 $X = X^1 \cup X^2 \cup \dots \cup X^c$,并选取合适的邻域参数 K 或 ε ,在 X^i ($i = 1, 2, \dots, c$)上构造一个邻域图,共 c 个子邻域图.

Step 2: 与MCM-ISM-AP算法的Step 2一样.

Step 3: 与MCM-ISM-AP的Step 3唯一不同的

是权重的增大,将 $d(WM_i, WM_j)$ 更新为 $d(WM_i, WM_j) = \gamma \times d(WM_i, WM_j)$, $\gamma > 1$,这样在 X 上形成了唯一的邻域图 G ,计算出任意点对 x_i 与 x_j 之间的最短路径的长度 $d_G(x_i, x_j)$.

值得一提的是,从表面上看,尽管上述步骤与MCM-ISM-AP的前3步类似,但SK-MCM-ISM-AP是在Step 1利用了类标签信息对数据集进行划分的,所以该算法是有监督的,而MCM-ISM-AP算法则是基于类簇在空间中分散很开的假设条件下形成多个子邻域图的.

3.2 测试数据集的低维特征空间表示

与MCM-ISM-AP算法的Step 5类似,将SK-MCM-ISM-AP算法Step 3得到的 $d_G(x_i, x_j)$ 写成矩阵形式,记 $D^2 = (d_G(x_i, x_j)^2)_{N \times N}$,并构造矩阵

$$K(D^2) = -\frac{1}{2}HD^2H. \quad (2)$$

但如果数据集受到噪声影响,则不能保证 $K(D^2)$ 为Mercer核矩阵,这一点文献[5]作了验证,并通过加常数的方法来保证 $K(D^2)$ 正定.本文也同样采取这种策略,令

$$d'_G(x_i, x_j) = d_G(x_i, x_j) + c(1 - \delta_{ij}), \quad (3)$$

其中 δ_{ij} 为克罗内克符号,即在不同样本点之间的原始最短路径长度上加上常量 c .这里要求常量 $c \geq c^*$, c^* 为以下矩阵 M 的最大特征值:

$$M = \begin{pmatrix} \mathbf{0} & 2K(D^2) \\ -I & -4K(D) \end{pmatrix}. \quad (4)$$

将式(3)替换(2)得到新的矩阵 K' ,即

$$K' = K(D^2) + 2cK(D) + \frac{1}{2}c^2H. \quad (5)$$

这样就保证了新的矩阵 K' 是Mercer核矩阵.对 K' 进行特征分解可得

$$K' = VAV^T, \quad (6)$$

从而得到训练数据集的低维特征空间表示,即

$$Y = A^{\frac{1}{2}}V. \quad (7)$$

对于一个待分类的数据点 $x_t \in R^n$,根据Mercer定理, K' 能表示为

$$K'_{ij} = k(x_t, x_j) = \langle \phi(x_t), \phi(x_j) \rangle, \quad (8)$$

其中 $\phi(\cdot)$ 为一个原始空间到特征空间的非线性映射函数.利用KPCA中类似的技巧,可计算出 x_t 的低维映射 y_t ,有

$$[y_t]_i = \frac{1}{\sqrt{\lambda_i}} \sum_{j=1}^N [v_i]_j k(x_t, x_j). \quad (9)$$

其中: $[y_t]_i$ 为 y_t 的第 i 个分量; λ_i, v_i 分别为 K' 的第 i 个特征值和第 i 个特征向量; $[v_i]_j$ 为 v_i 的第 j 个分量; $k(x_t, x_j)$ 为待分类样本 x_t 与训练样本点 x_j 在特征

空间中的映像 $\phi(x_t)$ 与 $\phi(x_j)$ 的内积 $\langle \phi(x_t), \phi(x_j) \rangle$. $k(x_t, x_j)$ 的计算过程如下:

采用与式 (3) 同样的方法, 对 x_t 与 x_j 之间的测地线距离 $d_G(x_t, x_j)$ 进行修正, 有

$$d'_G(x_t, x_j) = d_G(x_t, x_j) + c. \quad (10)$$

值得一提的是, 根据 ISOMAP 思想, $d'_G(x_t, x_j)$ 在低维空间等于其像 $\phi(x_t)$ 与 $\phi(x_j)$ 之间的欧氏距离 $d(\phi(x_t), \phi(x_j))$, 而 $d(\phi(x_t), \phi(x_j))$ 的平方可以写为

$$\begin{aligned} (d(\phi(x_t), \phi(x_j)))^2 &= \\ [\phi(x_t) - \phi(x_j)]^T [\phi(x_t) - \phi(x_j)] &= \\ (\phi(x_t))^T \phi(x_t) + (\phi(x_j))^T \phi(x_j) - 2(\phi(x_t))^T \phi(x_j). \end{aligned} \quad (11)$$

将上式移项可得

$$\begin{aligned} (\phi(x_t))^T \phi(x_j) &= \\ \frac{1}{2}((\phi(x_t))^T \phi(x_t) + (\phi(x_j))^T \phi(x_j) - & \\ (d(\phi(x_t), \phi(x_j)))^2). \end{aligned} \quad (12)$$

考虑 $\phi(\cdot)$ 是中心化的, 则有

$$\sum_{j=1}^N (\phi(x_t))^T \phi(x_j) = 0. \quad (13)$$

根据上式, 对式 (11) 中的 j 分别取 $1, 2, \dots, N$, 并进行累加求平均可得

$$\begin{aligned} \frac{1}{N} \sum_{j=1}^N (d(\phi(x_t), \phi(x_j)))^2 &= \\ (\phi(x_t))^T \phi(x_t) + \frac{1}{N} \sum_{j=1}^N (\phi(x_j))^T \phi(x_j). \end{aligned} \quad (14)$$

将上式进行移项可得

$$\begin{aligned} (\phi(x_t))^T \phi(x_t) &= \frac{1}{N} \sum_{j=1}^N (d(\phi(x_t), \phi(x_j)))^2 - \\ \frac{1}{N} \sum_{j=1}^N (\phi(x_j))^T \phi(x_j). \end{aligned} \quad (15)$$

将上式代入式 (12) 可得

$$\begin{aligned} (\phi(x_t))^T \phi(x_j) &= \\ \frac{1}{2} \left(\frac{1}{N} \sum_{j=1}^N (d(\phi(x_t), \phi(x_j)))^2 - \right. & \\ \left. \frac{1}{N} \sum_{j=1}^N (\phi(x_j))^T \phi(x_j) + (\phi(x_j))^T \phi(x_j) - \right. & \\ (d(\phi(x_t), \phi(x_j)))^2 \Big) &= \\ \frac{1}{2} \left(\frac{1}{N} \sum_{j=1}^N (d'_G(x_t, x_j))^2 - \frac{1}{N} \sum_{j=1}^N K'_{jj} + \right. & \\ \left. K'_{jj} - (d'_G(x_t, x_j))^2 \right) = k(x_t, x_j). \end{aligned} \quad (16)$$

由上式可以看出, 要求出 $k(x_t, x_j)$, 需计算 x_t 与所有训练样本点之间的测地线距离.

综上所述, 实现 SK-MCMM-ISOMAP 第 2 个目标的步骤如下:

Step 1: 令 $D^2 = (d_G(x_i, x_j))^2_{N \times N}$, 并构造矩阵 $K(D^2) = -\frac{1}{2}HD^2H$;

Step 2: 构造矩阵

$$M = \begin{pmatrix} \mathbf{0} & 2K(D^2) \\ -I & -4K(D) \end{pmatrix},$$

求出其最大特征值 c^* ;

Step 3: 选取常数 $c(c \geq c^*)$, 并构造矩阵

$$K' = K(D^2) + 2cK(D) + \frac{1}{2}c^2H;$$

Step 4: 对矩阵 K' 进行特征分解有 $K' = V\Lambda V^T$;

Step 5: $Y = \Lambda^{\frac{1}{2}}V$;

Step 6: 根据式 (16), 求出

$$[y_t]_i = \frac{1}{\sqrt{\lambda_i}} \sum_{j=1}^N [v_i]_j k(x_t, x_j).$$

当得到待分类的数据点 x_t 在低维特征空间的表示 y_t 后, 采用 k NN 分类器, 对 x_t 进行分类.

4 实 验

为了验证 SK-MCMM-ISOMAP 在人脸识别上的性能, 首先, 在 ORL^[9], Yale^[10], PIE^[11], FERET^[12], Umist^[13] 和 JAFFE^[14] 6 个常用的人脸数据集上, 与经典的人脸识别算法 Eigenfaces 和 Fisherfaces 进行比较; 然后, 在 ORL 数据集上与杨教授^[15] 提出的 KPCA+LDA 算法进行了比较. 所有图像均被预处理成分辨率为 32×32 , 256 灰度级的图像. 其中前 4 个经过该预处理的人脸数据集直接从浙江大学 CAD& CG 国家实验室获得^[16], 每个数据集中的某个人对应的部分典型图像如图 1 所示, 各个图像数据库的简要信息如表 1 所示.

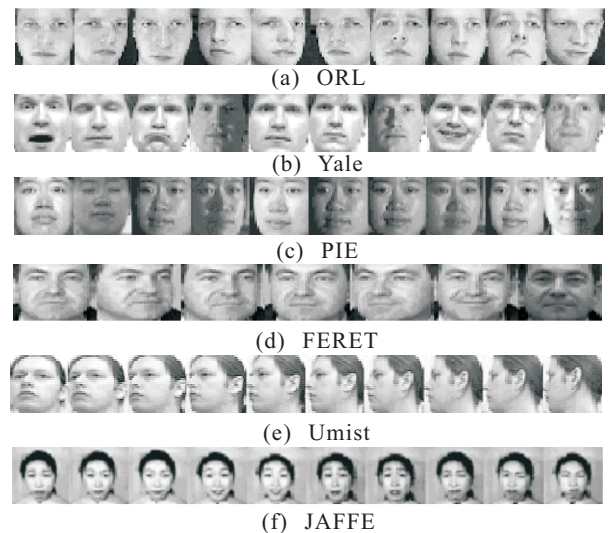


图 1 几幅典型示例图像

表1 实验所用的人脸数据集

数据集	总的图像数/个	类别数(人数)	每人对应的图像数
ORL	400	40	10
Yale	165	11	15
PIE	680	68	10
FERET	1400	200	7
Umist	575	20	19到48不等
JAFFE	213	10	20到23不等

根据有限数据的实验结果进行分类预测性能评估是机器学习领域中存在较多争议问题,这不仅是因为在分类模型预测性能评估体系中存在很多模型评估准则,而且还存在许多不同的模型评估方法.在本实验中,采用10次10折交叉验证来评估不同人脸识别方法的性能^[17].其基本思想是:将有标签的样本集 $X = [(x_1, l_1), \dots, (x_N, l_N)] (l_i \in \{1, 2, \dots, c\})$ 随机划分为10个不相交的子集 $X = X^1 \cup X^2 \cup \dots \cup X^{10}$, 且每个子集都有 $N/10$ 个样本点.对于每个分类器在每个数据集上,共重复10次,每次执行10折交叉验证.在第 i 次第 k 折的实验中,第 m 个分类器的准确率记为 $C_{i,k}^m$, 然后计算出平均准确率为

$$\bar{C}^m = \frac{1}{100} \times \sum_{i=1}^{10} \sum_{k=1}^{10} C_{i,k}^m, \quad (17)$$

标准差为

$$S^m = \sqrt{\frac{1}{10 \times 10 - 1} \sum_{i=1}^{10} \sum_{k=1}^{10} (C_{i,k}^m - \bar{C}^m)^2}. \quad (18)$$

为刻画某个人脸数据集中某一类样本子集用来训练和测试的样本数量比重,引入变量

$$\rho = \frac{|(X^i)_{\text{test}}|}{|(X^i)_{\text{train}}|}. \quad (19)$$

其中: $|(X^i)_{\text{test}}|$ 与 $|(X^i)_{\text{train}}|$ 表示第 i 类样本集 X^i 中分别用来测试和训练的样本数量,且满足 $(X^i)_{\text{train}} \cap (X^i)_{\text{test}} = \phi$.

为了全面评价 SK-MCMM-ISOMAP 算法在人脸识别任务中的准确率,本文对低维特征空间维度 m 取10个不同的值,分别为10, 20, 30, ..., 100,且在两种情形下进行了实验:1)当每一类训练样本数量相对于测试样本数量充足时,本实验选择 $\rho = 1/9$,即

对任何一个人脸数据集,该数据集中的任何一类子数据集中,用来测试的样本数量与训练的样本数量比值为1/9,实验结果如图2所示.图2给出了 SK-MCMM-ISOMAP, Eigenfaces 和 Fisherfaces 3种人脸识别算法在不同数据集不同维度上的准确率比较结果.其中:实线表示 Fisherfaces 算法,虚线表示 SK-MCMM-ISOMAP 算法,点划线表示 Eigenfaces 算法.2)当每一类训练样本集数量相对于测试样本集数量较少时,本实验选择 $\rho = 9$,即对任何一个人脸数据集,该数据集中的任何一类子数据集中,用来测试的样本数量是训练样本数量的9倍,实验结果如表2所示.表2给出了上述3种不同的人脸识别算法在不同数据集上最优准确率(10个准确率中最高的准确率),及该准确率对应的方差和维度.

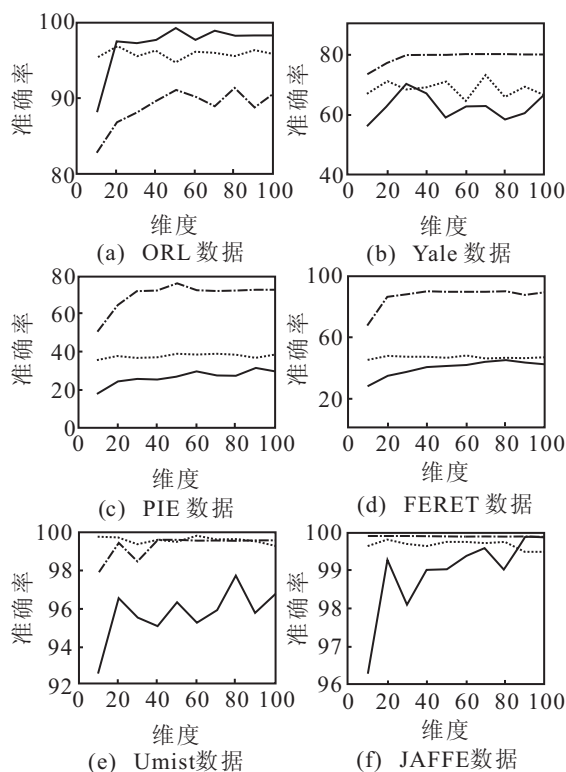


图2 $\rho=1/9$ 时3种不同的人脸识别算法在不同数据集不同维度上的准确率比较

从图2可以看出,当 $\rho = 1/9$,即训练样本集占的比重较高时,SK-MCMM-ISOMAP 算法在所有

表2 $\rho=9$ 时3种不同的人脸识别算法在不同数据集上最优准确率及对应的维度

数据集	SK-MCMM-ISOMAP		Eigenfaces		Fisherfaces	
	最优准确率(方差)	维度	最优准确率(方差)	维度	最优准确率(方差)	维度
ORL	55.63(1.34)	90	54.10(1.79)	70	53.60(1.45)	80
Yale	36.39(0.78)	70	35.18(1.54)	80	13.64(1.55)	30
PIE	9.60(2.31)	90	9.27(0.20)	50	8.29(1.08)	60
FERET	14.50(1.39)	80	14.31(0.38)	40	14.03(2.01)	60
Umist	72.35(2.61)	30	56.06(1.25)	90	76.81(1.04)	30
JAFFE	89.39(0.67)	10	79.06(1.77)	20	83.12(1.66)	20

数据集上的人脸识别准确率明显优于 Eigenfaces, 尤其在低维空间维度 m 的值较小时, 这种优势更明显; 同 Fisherfaces 的比较, 在 Yale, PIE 和 FERET 数据集上劣于 Fisherfaces, 但在其他 3 个数据集上的准确率与 Fisherfaces 相当, 尤其在维度较低时, 在 ORL 和 Umist 两个数据集上, SK-MCMM-ISOMAP 的性能要稍优于 Fisherfaces, 如当低维空间的维度 $m = 10$ 时, SK-MCMM-ISOMAP 与 Fisherfaces 在 ORL 数据集上的识别准确率分别为 95.23% 和 87.34%, 在 Umist 数据集上的识别准确率分别为 99.76% 和 97.56%。

从表 2 可以看出, 当 $\rho = 9$, 即训练样本集所占的比重较低时, SK-MCMM-ISOMAP 算法在所有数据集上的性能优于 Eigenfaces, 在其中 5 个数据集上的性能要优于 Fisherfaces。但在 Umist 数据集上, Fisherfaces 的准确率最高, 达到 76.81%, 而 SK-MCMM-ISOMAP 只达到 72.35%。出现这种情况的原因可能是因为 Umist 数据集中每个类别所包含的图像个数较多, 在 $\rho = 9$ 的情况下, 每类参加训练的样本数也有 2~3 个, 因此受训练样本数的影响相对其他数据集来说较小。由表 2 可知, 在这 3 种人脸识别算法中, SK-MCMM-ISOMAP 算法对训练样本集的大小有较好的鲁棒性, 且结合图 2 可以得出 Fisherfaces 受训练样本集的大小影响最大。

另外, 本文也将该算法与杨教授提出的 KPCA+LDA 算法在 ORL 数据集上进行了实验, 如表 3 所示。从表 3 可以看出, KPCA+LDA 的分类准确性比 Fisherfaces 和 SK-MCMM-ISOMAP 有所提高, 但受训练样本个数的影响比 SK-MCMM-ISOMAP 算法稍大。

表 3 两种方法在 ORL 数据集上的性能

ρ	SK-MCMM-ISOMAP		KPCA+LDA	
	最优准确率	维度	最优准确率	维度
1/9	97.35	20	98.60	50
9	55.63	90	55.01	70

5 结 论

本文在早先提出的 MCMM-ISOMAP 算法的基础上, 结合 Kernel ISOMAP 算法的泛化特性, 提出了一种有监督核化的多类多流形 ISOMAP 算法 (SK-MCMM-ISOMAP)。该算法既保持了 Kernel ISOMAP 算法的泛化特性, 同时又能有效完成具有高维小样本特性的人脸数据集的分类任务, 避免了 ISOMAP-C 算法在解决人脸识别任务时的不足。实验结果表明, 当训练样本集所占比重较大时, SK-MCMM-ISOMAP 在所有人脸数据集上的准确率要优于 Eigenfaces, 部分数据集上的效果与 Fisherfaces 相当; 当训练样本集所占比重较小时, 该算法的总体

性能均优于 Eigenfaces 和 Fisherfaces, 即 SK-MCMM-ISOMAP 算法对训练样本集的大小有良好的鲁棒性。不足之处在于对于一个待分类的样本点, 若要求其低维坐标, 需求出该点与其他所有训练样本点之间的测地线距离, 这是很耗时的, 如何高效地解决该问题, 使本文算法在实际中得到应用, 将是未来值得研究的方向。

参考文献(References)

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. J 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 Trans on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711-720.
- [3] Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323.
- [4] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.
- [5] Choi H, Choi S. Robust kernel ISOMAP[J]. Pattern Recognition, 2007, 40(3): 853-862.
- [6] Zhao D F, Li Y. Incremental isometric embedding of high dimensional data using connected neighborhood graphs[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(1): 86-98.
- [7] Geng X, Zhan D C, Zhou Z H. Supervised nonlinear dimensionality reduction for visualization and classification[J]. IEEE Trans on Systems, Man, and Cybernetics, Part B, 2005, 35(6): 1098-1107.
- [8] Cheng Q C, Wang H Y, Feng Y, et al. A multi-class multi-manifold learning algorithm based on ISOMAP[C]. Proc of the 1st CJK Joint Workshop on Pattern Recognition. New York: IEEE Press, 2009, 2: 813-817.
- [9] Olivetti & Oracle Research Laboratory. The Olivetti & Oracle Research Laboratory Face Database of Faces[EB/OL]. [2010-5]. <http://www.cam-orl.co.uk/facedatabase.html>.
- [10] Yale University Face Database[EB/OL]. [2010-5]. <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>.
- [11] Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression (PIE) database[C]. Proc of the IEEE Int Conf on Automatic Face and Gesture Recognition. Washington DC: IEEE Computer Society, 2002: 46-51.
- [12] Phillips P J, Moon H, Rizvi S A, et al. The FERET evaluation methodology for face-recognition algorithms[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2000, 22(10): 1090-1104.