

基于局部稀疏表示和线性鉴别分析的典型相关分析

夏建明, 杨俊安, 康 凯

(电子工程学院 a. 通信对抗系, b. 安徽省电子制约技术重点实验室, 合肥 230037)

摘要: 为在特征融合中综合利用数据的类别信息和数据结构中所蕴含的自然鉴别信息, 提出一种基于局部稀疏表示和线性鉴别分析的典型相关分析算法. 首先利用局部稀疏表示模型, 以较小的计算复杂度获取局部稀疏重构矩阵; 然后在典型相关分析的框架中实现对局部稀疏结构保持、线性鉴别分析和组合特征相关性的联合优化, 增强了融合特征的鉴别能力. 在人工数据、多特征手写数据、人脸数据上的实验表明了所提出方法的有效性.

关键词: 特征融合; 典型相关分析; 局部稀疏表示; 线性鉴别分析

中图分类号: TP391.4

文献标志码: A

Canonical correlation analysis based on local sparse representation and linear discriminative analysis

XIA Jian-ming, YANG Jun-an, KANG Kai

(a. Department of Communication Countermeasure, b. Key Laboratory of Electronic Restriction of Anhui Province, Electronic Engineering Institute, Hefei 230037, China. Correspondent: XIA Jian-ming, E-mail: jianmingeei@163.com)

Abstract: The natural discriminating information contained in the data structure and class information of the datasets is very vital for the feature fusion. Then in order to utilize all the information, a canonical correlation analysis algorithm based on local sparse representation and linear discriminative analysis is proposed. Firstly, the local sparse representation method is utilized to obtain the sparse manifold reconstruction matrix with less computational complexity. Then, the united optimization is realized in the canonical correlation analysis scheme to constrain the sparse reconstructive relationship among each feature set with optimizing the combined discriminability and the feature correlation simultaneously, so that the discrimination capability of the feature extracted is increased. Finally, the simulation examples on artificial dataset, multiple feature database and facial databases are presented, and the experimental results show the effectiveness of the proposed method.

Key words: feature fusion; canonical correlation analysis; local sparse representation; linear discriminative analysis

0 引言

在模式识别应用中, 仅利用单模态数据提取特征会受到多种因素的困扰, 造成整体性能的下降. 融合多种异类信息, 能够充分利用信息的多样性和互补性, 减少目标信息的不确定性.

与最初将多组特征并列构成一个高维特征的传统融合方式不同, 典型相关分析(CCA)^[1]通过最大化两组特征经过投影之后的相关性而达到特征融合的目的, 已成功应用于模式识别领域^[2-3]. 但典型相关分析仅能提取模式的线性特征, 而且作为一种无监督学习方法, 融合结果往往分类效果较差. 后期相关

学者提出了多种改进方法, 一类方法在相关样本的选择范围或模式提取方式上进行改进, 如核典型相关分析(KCCA)^[4]将典型相关分析与核方法结合, 用以提取模式的非线性特征; 局部保持典型相关分析(LPCCA)^[5]仅最大化近邻样本之间的相关性; 子模式典型相关分析(SpCCA)^[6]综合了局部与全局特征矢量之间的相关最大化, 用以融合局部和全局信息. 但是这类方法没有利用样本的类别信息.

另一类方法针对CCA没有利用类别信息从而分类性能较差的问题进行改进, 如鉴别型典型相关分析(DCCA)^[7]将最大化类内相关和最小化类间相关作

收稿日期: 2013-04-14; 修回日期: 2013-11-02.

基金项目: 安徽省自然科学基金项目(1208085MF94, 1308085QF99); 国家自然科学基金项目(61272333).

作者简介: 夏建明(1982—), 男, 博士, 从事数据挖掘、机器学习的研究; 杨俊安(1965—), 男, 教授, 博士生导师, 从事信号处理、智能计算等研究.

为目标函数;局部鉴别型典型相关分析(LDCCA)^[8]针对 DCCA 没有考虑局部流形结构的缺点,在 DCCA 的基础上引入局部流形信息;增强组合特征判别性的相关分析(CECCA)^[9]针对分类任务同时优化组合特征的相关性和判别性,但是这类方法有的仅考虑了样本的类别信息而忽略了数据的结构信息,有的虽然考虑了数据的局部欧式结构,而欧氏距离并不能很好地度量高维样本之间的相似度.

近几年来,基于稀疏表示的机器学习方法在模式识别多个领域得到快速发展^[10-11].将样本间的全局稀疏重构权重作为一种自然鉴别信息引入模型成为解决问题的一种新思路.如 Zheng 等^[12]在图像分类问题中同时考虑了数据的几何结构信息和稀疏重构信息,提出了图形正则化的稀疏编码算法;Sun 等^[13]发现典型相关分析与最小二乘在一定情况下是等价的,据此提出了最小二乘典型相关分析(LS-CCA),同时对投影向量进行稀疏正则化约束;Hardoon 等^[14]先将一组特征变换到核空间,再在最大化特征相关性的同时增加对投影向量的稀疏正则化约束,提出了稀疏典型相关分析(SCCA);侯书东等^[15]在 CCA 的基础上引入了各组特征的稀疏保持项,提出了稀疏保持典型相关分析(SPCCA),有效融合了两组特征集结构中的鉴别信息,增强了特征的表达和鉴别能力.但这类方法的主要问题是没利用已知的样本类别信息,且从数据全局来寻找每个点的稀疏重构点的方法计算复杂度太高.此外,通过全局稀疏重构的方式获得的样本间关系并不一定能够表征数据的本质.2010年 Li 等^[16]提出局部线性重构模型(LSR),这种方法在目标点的邻域上寻找其重构点,这种方式既不同于传统稀疏重构模型在数据全局寻找稀疏重构点的方法,也不同于流形学习模型中保持全局或局部欧式结构的特点,以较小的运算代价获取了类似于全局稀疏重构的结果.

为综合利用数据类别信息和稀疏结构信息,并降低获取稀疏重构矩阵的运算复杂度,本文首先通过局部稀疏表示模型学习各特征集内样本在其邻域中的稀疏重构系数.在此基础上,结合 CCA 框架和线性鉴别分析思想实现对组合特征相关性、判别性的联合优化;同时保证各特征集中的局部稀疏重构关系得以保持,从而提高融合特征的分类效能,并有效降低算法的复杂度.

1 相关工作

1.1 典型相关分析

假设不同信源对同一对象的观测值为 (x_i, y_i) , $i = 1, 2, \dots, N$, 其中 $X = [x_1, x_2, \dots, x_N]$, $Y = [y_1,$

$y_2, \dots, y_N]$. 典型相关分析的目标是找到两组投影向量 w 和 u , 使得投影向量 $z_1 = w^T X$ 与 $z_2 = u^T Y$ 之间的相关性最大. 其判别函数为

$$\max_{w, u} \rho = \frac{w^T S_{xy} u}{\sqrt{w^T S_{xx} w} \sqrt{u^T S_{yy} u}}. \quad (1)$$

运用拉格朗日乘子法进行优化可得如下广义特征方程:

$$\begin{bmatrix} 0 & S_{xy} \\ S_{xy}^T & 0 \end{bmatrix} \begin{bmatrix} w \\ u \end{bmatrix} = \lambda \begin{bmatrix} S_{xx} & 0 \\ 0 & S_{yy} \end{bmatrix} \begin{bmatrix} w \\ u \end{bmatrix}, \quad (2)$$

其中 S_{xx} 、 S_{yy} 和 S_{xy} 分别为样本集 X 和 Y 的协方差矩阵、互协方差矩阵.

1.2 线性鉴别分析

线性鉴别分析的目标是寻找一个投影向量,使得映射到投影空间的数据类内尽可能紧凑,类间尽可能分离.设样本集 $X = [x_1, x_2, \dots, x_N] \in R^{m \times N}$, 分别属于 l 个不同类别,则线性鉴别分析的目标函数为

$$\max_v \frac{v^T S_B v}{v^T S_W v}. \quad (3)$$

其中: v 为投影矩阵, S_B 、 S_W 分别为类间散布矩阵和类内散布矩阵,即

$$S_B = \sum_{i=1}^l n_i (m_i - m)(m_i - m)^T, \quad (4)$$

$$S_W = \sum_{i=1}^l \left(\sum_{j=1}^{n_i} (x_i^j - m_i)(x_i^j - m_i)^T \right). \quad (5)$$

m 为样本总均值, m_i 为第 i 类样本均值, n_i 为第 i 类样本数量.

1.3 全局稀疏重构

全局稀疏重构矩阵的获得是众多基于稀疏表示的机器学习方法的基础.设样本集 $X = [x_1, x_2, \dots, x_N] \in R^{M \times N}$, 全局稀疏重构矩阵 $A = [\alpha_1, \alpha_2, \dots, \alpha_N] \in R^{(N-1) \times N}$. 对于任一个样本 x_i , 都存在一个子样本集 $X_i = [x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_N] \in R^{M \times (N-1)}$, 稀疏表示的目标就是要找到一个稀疏的列向量 $\alpha_i \in R^{N-1}$, 使得 $x_i = X_i \alpha_i$. 目标函数表达式为

$$\min_{\alpha_i} \|\alpha_i\|_1; \quad \text{s.t. } x_i = X_i \alpha_i. \quad (6)$$

考虑到重构误差及数据中的噪声,式(6)的约束条件一般无法成立,则上述目标函数改写为

$$\min_{\alpha_i} \|x_i - X_i \alpha_i\|_2 + \lambda \|\alpha_i\|_1. \quad (7)$$

逐次求解式(7)便可得到全局稀疏重构矩阵 A . 但是,这种从样本集整体中寻找被表示样本的稀疏重构点的方式,计算复杂度较大.求得一个样本的稀疏表示理论运算复杂度为 $O(t^2(N-1))$, 其中 t 为重构权重中非零值的个数, $(N-1)$ 为子样本集 X_i 中样本的个数. 实际应用中,获得的 α_i 往往含有较多数值较小的非零值,运算复杂度趋向于 $O((N-1)^3)$.

1.4 局部稀疏表示模型

为减小获得全局稀疏重构矩阵的运算复杂度, 实现对数据间结构信息的把握, 文献[16]提出局部稀疏表示方法, 通过保持高维空间中样本与其邻域样本之间的稀疏重构关系来构造全局稀疏重构结构. 局部稀疏表示方法与传统的全局稀疏重构求解方法的关系, 类似于流形学习框架中的局部线性嵌入 (LLE) 算法同 ISOMAP 算法的关系.

相关数据设定同 1.3 节, 设最大邻域范围为 k_{\max} , 对于任一个样本 x_i , 都存在一个 x_i 的 k_{\max} 邻域样本集 $X'_i \in R^{M \times k_{\max}}$, 其邻域样本集的索引集合为 I , 局部稀疏表示的目标是在这个邻域中找到一个稀疏的列向量 $\alpha'_i \in R^{k_{\max}}$, 使得 $x_i = X'_i \alpha'_i$. 目标函数表达式为

$$\min_{\alpha'_i} \|\alpha'_i\|_1; \text{ s.t. } x_i = X'_i \alpha'_i \mathbf{1}^T, \alpha'_i = 1. \quad (8)$$

全局稀疏重构向量 α_i 与局部稀疏表示向量 α'_i 的关系为

$$\alpha_{ij} = \begin{cases} \alpha'_{ij}, & j \in I; \\ 0, & j \notin I. \end{cases} \quad (9)$$

同 1.3 节一样, 逐次求解可得到全局稀疏重构矩阵 $A = [\alpha_1, \dots, \alpha_N] \in R^{(N-1) \times N}$. 很明显, 由于仅需要在邻域范围内而不是在整个数据集中寻找稀疏重构点, 局部稀疏表示方法求得一个样本稀疏表示的理论运算复杂度为 $O(t^2 k_{\max})$, 其中 $t \leq k_{\max} \ll N - 1$, 其运算复杂度远小于全局稀疏重构方法.

2 基于局部稀疏表示模型和线性鉴别分析的典型相关分析

在获得局部稀疏重构矩阵后, 本文将利用优化策略综合重构矩阵以及典型相关分析、线性鉴别分析的目标函数, 得到最终的目标函数. 使融合后的特征满足: 1) 特征之间具有最大的相关性; 2) 融合后特征具有最佳的线性鉴别性; 3) 保持特征集数据间的局部稀疏重构结构. 其中, 最大化异类特征间的相关性可以利用不同模态之间的互补性来减少融合特征的不确定性, 而最佳线性鉴别目标函数的引入则保证最终的融合结果能有较好的分类效果. 通过保持特征集间的稀疏重构结构可充分利用原数据中的结构信息, 提高算法的稳定性和鲁棒性. 相关假设同上节. 设同一目标的两组特征集为 $X = [x_1, x_2, \dots, x_N]$, $Y = [y_1, y_2, \dots, y_N]$, 通过局部稀疏表示模型获得的重构矩阵为 X_S, Y_S , 融合后的数据为 $[w^T X \quad u^T Y]$. 由文献[17]可知, 求解式(1)可等价于求解如下优化问题:

$$\begin{aligned} & \max_{w, u} w^T S_{xy} u; \\ & \text{s.t. } w^T S_{xx} w + u^T S_{yy} u = 2. \end{aligned} \quad (10)$$

而式(3)的迹差表示形式为

$$\max_v v^T (S_B - S_W) v. \quad (11)$$

$S_B - S_W$ 可以进一步化简为

$$\begin{aligned} S_B - S_W &= \sum_{i=1}^l n_i (m_i - m)(m_i - m)^T - \\ & \sum_{i=1}^l \left(\sum_{j=1}^{n_i} (x_i^j - m_i)(x_i^j - m_i)^T \right) = \\ & \sum_{i=1}^l \left[n_i (m_i m_i^T - m m_i^T - m_i m^T + m m^T) - \right. \\ & \left. \sum_{j=1}^{n_i} (x_i^j (x_i^j)^T - m_i (x_i^j)^T - x_i^j m_i^T + m_i m_i^T) \right] = \\ & 2 \sum_{i=1}^l n_i m_i m_i^T - \left(\sum_{i=1}^l \sum_{j=1}^{n_i} x_i^j m^T + \sum_{i=1}^l \sum_{j=1}^{n_i} x_i^j (x_i^j)^T \right) = \\ & 2 \sum_{i=1}^l m_i \sum_{j=1}^{n_i} (x_i^j)^T - \left[\frac{1}{N} \sum_{i=1}^l \sum_{j=1}^{n_i} x_i^j \sum_{i=1}^l \sum_{j=1}^{n_i} (x_i^j)^T + \right. \\ & \left. \sum_{i=1}^l \sum_{j=1}^{n_i} x_i^j (x_i^j)^T \right]. \end{aligned} \quad (12)$$

式(12)写成矩阵形式为

$$S_B - S_W = 2XWX^T - XX^T = X(2W - I)X^T. \quad (13)$$

其中: I 为单位阵; $W = [W_{ij}]_{N \times N}$, 且有

$$W_{w,ij} = \begin{cases} \frac{1}{n_k}, & x_i \text{ 与 } x_j \text{ 为第 } K \text{ 类样本;} \\ 0, & \text{otherwise.} \end{cases} \quad (14)$$

n_k 为第 K 类样本的数目. 设 $A = 2W - I$, 线性鉴别分析目标函数可简化为

$$\begin{aligned} & \begin{bmatrix} w \\ u \end{bmatrix}^T (S_B - S_W) \begin{bmatrix} w \\ u \end{bmatrix} = \\ & 2w^T X(2W - I)Y^T u + w^T X(2W - \\ & I)X^T w + u^T Y(2W - I)Y^T u = \\ & 2w^T XAY^T u + w^T XAX^T w + u^T YAY^T u. \end{aligned} \quad (15)$$

为使融合后的数据集 X' 之间仍然保持原特征集中的数据结构, 需要

$$\begin{aligned} & \min_{X'} \sum_{i=1}^N \left\| X' - \sum_{j=1}^N X' c_j \right\|^2 = \\ & \min_{X'} X'(I - C)(I - C)^T X'^T. \end{aligned} \quad (16)$$

将相关参数代入式(16), 并与线性鉴别分析的目标函数结合, 综合设计目标函数如下:

$$\begin{aligned} & \max_{w, u} w^T X(I + 2A)Y^T u + w^T XAX^T w + u^T YAY^T u; \\ & \text{s.t. } w^T X(I - X_S)(I - X_S)^T X^T w + \end{aligned}$$

$$u^T Y(I - Y_S)(I - Y_S)^T Y^T u = 2. \quad (17)$$

即在线性鉴别分析的目标函数中加入对局部稀疏重构关系保持的约束, 使得最终融合得到的结果既有对数据类别信息的考虑, 又符合原特征集内部的数据结构. 运用拉格朗日乘子法可得式 (17) 的拉格朗日函数

$$\begin{aligned} L(w, u, \lambda) = & w^T X(I + 2A)Y^T u + w^T XAX^T w + u^T YAY^T u - \\ & \lambda(w^T X(I - X_S)(I - X_S)^T X^T w + \\ & u^T Y(I - Y_S)(I - Y_S)^T Y^T u - 2). \end{aligned} \quad (18)$$

分别关于 w 、 u 对式 (18) 求偏导, 可得

$$\frac{\partial L}{\partial w} = X(0.5I + A)Y^T u + XAX^T w - \lambda X(I - X_S)(I - X_S)^T X^T w = 0, \quad (19)$$

$$\frac{\partial L}{\partial u} = Y(0.5I + A)X^T w + YAY^T u - \lambda Y(I - Y_S)(I - Y_S)^T Y^T u = 0. \quad (20)$$

该问题可进一步转化为求解如下的特征值问题:

$$\begin{bmatrix} XAX^T & X(0.5I + 2A)Y^T \\ Y(0.5I + 2A)X^T & YAY^T \end{bmatrix} \begin{bmatrix} w \\ u \end{bmatrix} = \lambda \begin{bmatrix} X(I - X_S)(I - X_S)^T X^T & 0 \\ 0 & Y(I - Y_S)(I - Y_S)^T Y^T \end{bmatrix} \begin{bmatrix} w \\ u \end{bmatrix}. \quad (21)$$

类似于 CCA 的典型分量求解, 按照特征值从大到小选择对应的 d 维特征向量构成投影矩阵 w 和 u . 获得投影矩阵后, 可按 $z_1 = w^T X$ 和 $z_2 = u^T Y$ 对两特征集进行融合处理获得新特征集 $[w^T X \quad u^T Y]$.

综上所述, 本文方法的算法流程如下.

输入: 原始数据集 $X = [x_1, x_2, \dots, x_N]$, $Y = [y_1, y_2, \dots, y_N]$, 融合特征的维数为 $2d$;

输出: $2d$ 维新数据集 $Z = [w^T X \quad u^T Y]$.

Step 1: 输入数据集 X 、 Y , 并标准化.

Step 2: 求解式 (8) 和 (9), 获得数据集 X 、 Y 的局部稀疏重构矩阵 X_S 、 Y_S .

Step 3: 根据式 (21) 计算获得投影矩阵 w 和 u .

Step 4: 计算获得融合特征 Z , 运用近邻分类器对测试样本进行分类.

3 实验结果与分析

为验证本文所提出算法的有效性, 分别在人工数据集、多特征手写体数据集和人脸数据库上进行了实验, 比较了本文算法与 CCA、SPCCA、CECCA 相关最新算法的分类识别性能.

3.1 人工数据实验

在人工数据集上进行可视化实验, 考虑两个类别的数据流形互相近邻的情况, 数据为两个三叶草纽结,

每个三叶草纽结为一类, 各含 100 个点, 设原特征集为 X , 相应的另一特征集为 Y , 两数据集之间的关系有

$$Y = \begin{bmatrix} 0.6 & -0.5 & \sqrt{0.5} \\ 0.8 & 0.5 & -\sqrt{0.6} \\ 0.7 & 0.6 & \sqrt{0.54} \end{bmatrix} X + S_N. \quad (22)$$

其中: 噪声 S_N 满足高斯分布 $N(0.2, 1)$, 数据集 X 、 Y 的分布情况分别如图 1 和图 2 所示.




图 1 数据集 X 分布

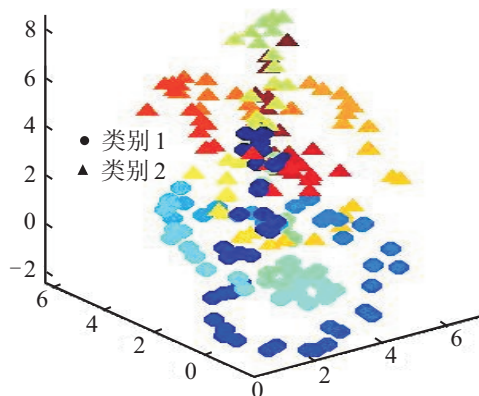


图 2 数据集 Y 分布

如图 1 和图 2 所示, 两个数据集中不同类别的流形结构非常接近, 不易分类; 而数据集经过矩阵转换以及噪声添加后, 已经无法保持三叶草纽结的形状. 图 3 分别给出了 CCA、CECCA、SPCCA 及本文方法的融合结果分布.

如图 3 所示, CCA 虽然揭示了特征间的线性相关关系, 但没有引入类别信息, 两类间存在一定的重叠; CECCA 虽然均引入了类别信息, 但没有考虑数据的结构信息, 对于这种流形结构明显且两类流形之间距离较近的数据, 其融合效果较差, 两类之间严重重叠; 而 SPCCA 虽然考虑了数据的结构信息, 但没有引入类别信息, 最终融合结果仅仅保持了原数据集正常分布的结构, 两类之间重叠明显. 本文方法同时考虑了数据结构信息以及类别信息, 类与类之间重叠较小. 表 1 为融合后特征的 Fisher 分值对比, 从中可看出本文方法结果要大大好于其他方法, 融合结果与其他方法相比, 类内更紧凑, 类间距更大, 说明本文所获取的组合特征有更强的判别性.

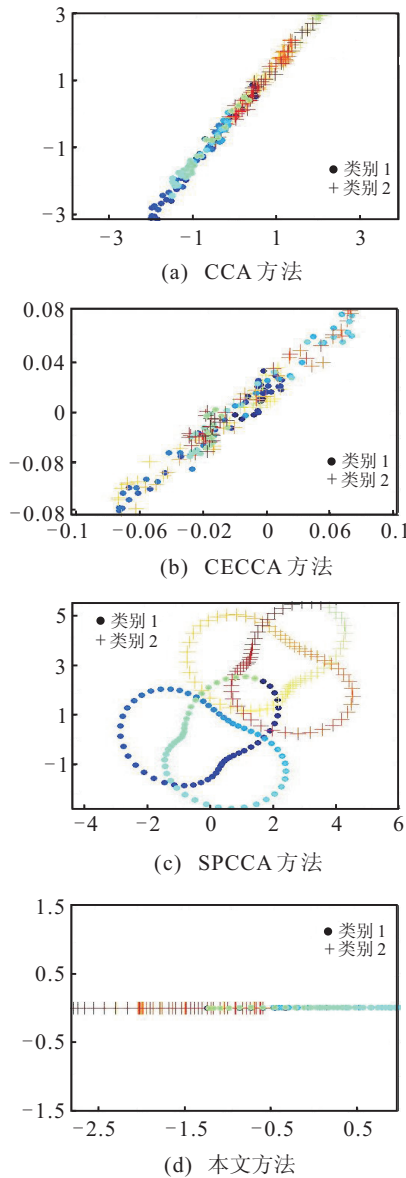


图 3 4 种算法融合数据分布对比

表 1 融合后特征的分类效能对比

指标	CCA	CECCA	SPCCA	本文方法
Fisher 分值	0.989	0.102	0.233	2.049

3.2 多特征手写体实验

采用多特征手写体数据集来检验本文算法性能. MFEAT 数据集包含 0~9 共 10 个数字的 6 组特征, 共 2000 个样本, 每类 200 个. 6 组特征包括轮廓相关特征 (FAC, 216 维), 傅立叶系数 (FOU, 76 维), KL 展开系数 (KAR, 64 维), 形态学特征 (MOR, 6 维), 像素均值 (PIX, 240 维), Zernike 矩 (ZER, 47 维).

实验中, 任选两个数据集进行组合, 对每种组合选取每类前 100 对样本作为训练集, 剩余样本作为测试集, 采用常用的内部一致性评价 Kappa 估计来衡量两组特征之间的差异性. 实验结果如表 2 所示. CCA 方法能够有效地融合两组特征, 但在两组特征之间存在较大差异时融合效果明显下降; SPCCA 考虑

表 2 多特征手写体集 MFEAT 上的识别率 %

数据组合	Kappa 估计	CCA	SPCCA	CECCA	本文方法
fac-fou	0.03	81.5(14)	88.5(16)	92.4(16)	97(16)
fac-kar	0.473	94.4(22)	94.5(22)	92.8(22)	94.7(22)
fac-mor	-0.142	69.7(12)	86.1(12)	87.5(12)	89.8(12)
fac-pix	0.411	93.9(20)	81.1(20)	90.4(20)	93.1(20)
fac-zer	0.086	80.7(42)	87.7(40)	81.9(40)	95(40)
fou-kar	0.014	90.3(18)	91.8(18)	92(18)	97.4(18)
fou-mor	0.105	77.2(12)	83.8(12)	79.2(12)	83(12)
fou-pix	0.022	89.7(20)	92.4(20)	91.5(20)	96.9(20)
fou-zer	0.396	81.8(20)	81(20)	80.4(20)	84.1(20)
kar-mor	-0.171	79.3(12)	82.3(12)	87.9(12)	89.8(12)
kar-pix	0.658	95.9(22)	95(22)	91.5(22)	95.8(22)
kar-zer	0.058	87.9(30)	88.9(30)	84.3(30)	94.3(30)
mor-pix	-0.17	74.6(12)	81.2(12)	89.9(12)	91.6(12)
mor-zer	0.202	69.5(12)	75.1(12)	74.9(12)	75.6(12)
pix-zer	0.0678	72.6(20)	82.6(20)	77(20)	92.6(20)

了样本的稀疏重构关系; CECCA 考虑了样本的类别信息, 在一定程度上弱化了 CCA 的缺点; 而本文方法由于兼顾了样本的结构信息和类别信息, 除在 fac-pix、kar-pix 和 fou-mor 组合上分别略逊于 CCA、SPCCA 方法外, 在识别性能上普遍好于其他方法.

此外, 从特征差异角度来看, 在特征差异度较大的 fac-fou、fac-mor、kar-mor 等组合上本文方法与其他方法相比优势明显, 在特征差异度较小的 fac-kar、fou-zer 等组合上则优势不明显, 在差异度很小的 fac-pix、kar-pix 组合上甚至略逊于 CCA 方法. 这表明本文方法在融合互补性较强、冗余度较小的特征时效果要好于融合冗余度大的特征.

3.3 人脸识别实验

分别在 ORL、YALE 人脸数据库上进行人脸识别实验. 实验中, 将所有图像裁剪成 30×30 像素的图像. 首先将图像进行正交小波分解获取低频分量作为样本的第二特征集, 然后对两组特征进行 PCA 降维, 以增强算法的稳定性和消除小样本问题的出现. ORL 人脸数据库包括 40 个人的 10 幅人脸图像, 每人 10 幅图像, 随机选择每人的 5 幅图像作为训练集, 其余 5 幅作为测试集. 实验中 PCA 降维到 42 维. Yale 人脸数据库包含 15 个人的 165 幅灰度图像, 选取每人 5 幅图像作为训练, 其余 6 幅用作测试. 实验中 PCA 降维到 48 维. 表 3 为结果对比.

表 3 不同方法在人脸数据集上的识别率对比 %

数据库	CCA	SPCCA	CECCA	本文方法
ORL	86(36)	92.5(36)	81(36)	93.5(36)
YALE	64.4(34)	93.7(34)	92.8(34)	94.5(34)

由表 3 可知: 1) 由于 CCA 没有利用样本原有的内在结构及类别信息, 在处理高维数据时, 融合特征分类效果有所下降, 高维特征中所含有的噪声及与分类无关的信息干扰了所抽取低维特征的鉴别能力; 2) SPCCA、CECCA 在 CCA 的框架中分别利用

了融合数据的稀疏结构信息、类别信息,其融合效果好于CCA,其中SPCCA由于利用了全局稀疏重构矩阵中的鉴别信息,效果要好于仅利用类别信息的CECCA,而本文方法综合利用了两类信息,融合效果好于其他方法.表4为不同方法在人脸数据上的运算时间对比,由表4可知:由于不要求解样本间的结构关系,CCA、CECCA方法运算效率较高,其中CCA方法仅以不同数据间的相关性为目标,计算复杂度最小;而PCCA、本文方法都需要计算样本之间的重构关系,计算复杂度大大增加.本文方法采用不需从数据全局寻找重构点的局部稀疏表示方法,相对而言计算复杂度显著优于SPCCA.

表 4 不同方法在人脸数据集上运算时间对比

数据集(数据个数×维数)	CCA	SPCCA	CECCA	本文方法
ORL(400×42)	0.013	133.57	0.11	2.18
YALE(165×48)	0.010	46.56	0.29	1.12

4 结 论

在典型相关分析的基础上,本文综合考虑了样本间的局部稀疏重构特性和类别信息,提出了一种新的特征融合方法.由于算法同时利用了样本的局部稀疏重构信息和标签的类别信息,能够获取更具鉴别性的融合特征,算法在人工数据、多特征手写体数据和人脸数据集中验证了其可行性.然而,实际处理多模态特征融合问题时,不同特征间的测度往往相差很大,此时用一个统一的测度去处理这类数据将削弱融合的效果,如何处理这类数据将是以后的研究重点.

参考文献(References)

- [1] 孙权森,曾生根,王平安,等.典型相关分析的理论及其在特征融合中的应用[J].计算机学报,2005,28(9):1524-1533.
(Sun Q S, Zeng S G, Weng P A, et al. The theory of canonical correlation analysis and its application to feature fusion[J]. Chinese J of Computers, 2005, 28(9): 1524-1533.)
- [2] Paramveer S Dhillon, Jordan Rodu, Dean P Foster, et al. Two step CCA: A new spectral method for estimating vector models of words[C]. Proc of the 29th Int Conf on Machine Learning, Edinburgh, 2012: 1043-1048.
- [3] 庄凌,庄越挺,吴江琴,等.一种基于稀疏典型性相关分析的图像检索方法[J].软件学报,2012,23(5):1295-1304.
(Zhuang L, Zhuang Y T, Wu J Q, et al. Image retrieval approach based on sparse canonical correlation analysis[J]. J of Software, 2012, 23(5): 1295-1304.)
- [4] Melzer T, Reiter M, Bischof H. Appearance models based on kernel canonical correlation analysis[J]. Pattern Recognition, 2003, 36(9): 1961-1971.
- [5] Sun T K, Chen S C. Locality preserving CCA with applications to data visualization and pose estimation[J]. Image and Vision Computing, 2007, 25(5): 531-543.
- [6] 洪泉,陈松灿,倪雪蕾.子模式典型相关分析及其在人脸识别中的应用[J].自动化学报,2008,34(1):21-30.
(Hong Q, Chen S C, Ni X L. Sub-pattern canonical correlation analysis with application in face recognition[J]. Acta Automatica Sinica, 2008, 34(1): 21-30.)
- [7] Sun T K, Chen S C, Yang J Y, et al. A novel method of combined feature extraction for recognition[C]. Proc of the 8th IEEE Int Conf on Data Mining. Pisa, 2008: 1043-1048.
- [8] Peng Yan, Zhang Daoqiang, Zhang Jianchun. A new canonical correlation analysis algorithm with local discrimination[J]. Neural Processing Letters, 2009, 31(1): 1-15.
- [9] 周旭东,陈晓红,陈松灿.增强组合特征判别性的典型相关分析[J].模式识别与人工智能,2012,25(2):285-291.
(Zhou X D, Chen X H, Chen S C. Combined-feature-discriminability enhanced canonical correlation analysis[J]. PRAI, 2012, 25(2): 285-291.)
- [10] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [11] Qiao L S, Chen S C, Tan X Y. Sparsity preserving projections with applications to face recognition[J]. Pattern Recognition, 2010, 43(1): 331-334.
- [12] Miao Zheng, Jiajun Bu, Chun Chen, et al. Graph regularized sparse coding for image representation[J]. IEEE Trans on Image Processing, 2011, 20(5): 1327-1336.
- [13] Sun L, Ji S W, Ye J. Canonical correlation analysis for multilabel classification: A least squares formulation, extensions and analysis[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2011, 33(1): 194-200.
- [14] Haroon D R, Shawe-Taylor J. Sparse canonical correlation analysis[J]. Machine Learning, 2011, 83(3): 331-353.
- [15] 侯书东,孙权森.稀疏保持典型相关分析及在特征融合中的应用[J].自动化学报,2012,38(4):659-665.
(Hou S D, Sun Q S. Sparsity preserving canonical correlation analysis with application in feature fusion[J]. Acta Automatica Sinica, 2012, 38(4): 659-665.)
- [16] Chun-Guang Li, Jun Guo, Hong-Gang Zhang. Local sparse representation based classification[C]. Int Conf on Pattern Recognition, 2010: 649-652.
- [17] Via J, Santamaria I, Perez J. A learning algorithm for adaptive canonical correlation analysis of several data sets[J]. Neural Networks, 2007, 20(1): 139-152.

(责任编辑:孙艺红)