




JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所


中国图象图形学报

2015
06
VOL.20

ISSN1006-8961
CN11-3758/TB



高光谱影像分类 P836



第20卷第6期（总第230期）

2015年6月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院遥感与数字地球研究所

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 李小文

编辑出版《中国图象图形学报》编辑出版委员会

邮政信箱 北京9718信箱

邮 编 100101

电子信箱 jig@radi.ac.cn

电 话 010-64807995

网 址 www.cjig.cn

广告经营许可证 京朝工商广字第0361号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

（邮政信箱：北京399信箱 邮编：100048）

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Institute of Remote Sensing and Digital Earth, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief LI Xiaowen

Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics

P.O.Box 9718, Beijing, P.R.China

Zip code 100101

E-mail jig@radi.ac.cn

Telephone 010-64807995

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China))

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB


ISSN 1006-8961

CODEN ZTTXFZ

国外发行代号 M1406

国内邮发代号 82-831


国内定价 50.00元



边缘结构保持的加权BDTV
全光场图像超分辨率重建
(第0733页)



基于超像素的多主体图像交
互分割(第0764页)



谐波分析光谱角制图高光谱
影像分类(第0836页)

图像处理和编码

边缘结构保持的加权BDTV全光场图像超分辨率重建

张旭东, 李梦娜, 张骏, 胡良梅, 王一 0733

基于Arnold映射的分块双层自适应扩散图像加密算法

徐亚, 张绍武 0740

结合梯度信息的特征相似性图像质量评估

苗莹, 易三莉, 贺建峰, 邵党国 0749

图像分析和识别

复杂场景下自适应背景减除算法

邵奇可, 周宇, 李路, 陈庆章 0756

基于超像素的多主体图像交互分割

伯彭波, 袁野, 王宽全 0764

采用金字塔纹理和边缘特征的图像烟雾检测

李红娣, 袁非牛 0772

结合手指检测和HOG特征的分层静态手势识别

刘淑萍, 刘羽, 於俊, 汪增福 0781

形状角计算改进及其在矩形目标识别中的应用

孟伟荣, 李辉, 方黎勇, 白金平 0789

融合图像感知哈希技术的运动目标跟踪

李子印, 朱明凌, 陈柱 0795

利用快速傅里叶变换的目标尺度自适应回归跟踪

张浪, 侯志强, 余旺盛, 许婉君 0805

基于点云属性信息的平面标靶特征提取

刘燕萍, 贾东峰 0815

融合局部思想和协作表达的鲁棒分类

楼宋江, 赵小明, 于海涛, 张石清 0822

计算机图形学

草绘3维人体建模的模板形变方法

李毅, 刘兴川, 孙亭 0828

遥感图像处理

谐波分析光谱角制图高光谱影像分类

杨可明, 刘飞, 孙阳阳, 魏华锋, 史钢强 0836

倾斜航空影像的城区DSM生成

吴军, 程门门, 姚泽鑫, 彭智勇, 李俊, 马峻 0845

封面图片由中国科学院遥感与数字地球研究所高光谱遥感应用技术研究室张霞研究员提供

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Edge preserved light field image super-resolution based on weighted BDTV model (P0733)



Interactive multiphase image segmentation based on superpixels (P0764)



Classification algorithm of hyperspectral imagery by harmonic analysis and spectral angle mapping (P0836)

Image Processing and Coding

Edge preserved light field image super-resolution method based on weighted BDTV model

Zhang Xudong, Li Mengna, Zhang Jun, Hu Liangmei, Wang Yi 0733

Encryption algorithm of image blocking and double adaptive diffusion with Arnold mapping

Xu Ya, Zhang Shaowu 0740

Image quality assessment of feature similarity combined with gradient information

Miao Ying, Yi Sanli, He Jianfeng, Shao Dangguo 0749

Image Analysis and Recognition

Adaptive background subtraction approach of Gaussian mixture model

Shao Qike, Zhou Yu, Li Lu, Chen Qingzhang 0756

Interactive multiphase image segmentation based on superpixels

Bo Pengbo, Yuan Ye, Wang Kuanquan 0764

Image based smoke detection using pyramid texture and edge features

Li Hongdi, Yuan Feiniu 0772

Hierarchical static hand gesture recognition by combining finger detection and HOG features

Liu Shuping, Liu Yu, Yu Jun, Wang Zengfu 0781

Improved shape angle computation and its application in detection of rectangular

Meng Weirong, Li Hui, Fang Liyong, Bai Jinping 0789

Object tracking algorithm based on perception hash technology

Li Ziyin, Zhu Mingling, Chen Zhu 0795

Scale adaptive regression tracking method based on fast Fourier transform

Zhang Lang, Hou Zhiqiang, Yu Wangsheng, Xu Wanjuan 0805

Feature extraction of flat target based on point cloud attribute information

Liu Yanping, Jia Dongfeng 0815

Locality constrained collaborative representation classification for robust classification

Lou Songjiang, Zhao Xiaoming, Yu Haitao, Zhang Shiqing 0822

Computer Graphics

Sketch-based method for 3D human modeling using template deformation

Li Yi, Liu Xingchuan, Sun Ting 0828

Remote Sensing Image Processing

Classification algorithm of hyperspectral imagery by harmonic analysis and spectral angle mapping

Yang Keming, Liu Fei, Sun Yangyang, Wei Huafeng, Shi Gangqiang 0836

Automatic generation of high-quality urban DSM with airborne oblique images

Wu Jun, Cheng Menmen, Yao Zexin, Peng Zhiyong, Li Jun, Ma Jun 0845

中图分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2015)06-0822-06

论文引用格式: Lou S J, Zhao X M, Yu H T, Zhang S Q. Locality constrained collaborative representation classification for robust classification[J]. Journal of Image and Graphics, 2015, 20(6): 0822-0827. [楼宋江, 赵小明, 于海涛, 张石清. 融合局部思想和协作表达的鲁棒分类[J]. 中国图象图形学报, 2015, 20(6): 0822-0827.][DOI:10.11834/jig.20150612]

融合局部思想和协作表达的鲁棒分类

楼宋江¹, 赵小明¹, 于海涛², 张石清¹

1. 台州学院图像处理与模式识别研究所, 台州 318000; 2. 哈尔滨工程大学计算机科学与技术学院, 哈尔滨 150001

摘要: 目的 协作表达分类算法在人脸识别实验上表现出较好的性能,但其未考虑样本的局部特性,且算法只能处理测试样本中的噪声,未能有效处理训练样本集中的噪声。针对这两个问题,提出融合局部思想和协作表达的鲁棒分类算法。方法 一方面,在训练集上,通过奇异值分解 SVD 得到其有效表达,丢弃一些噪声;另一方面,算法考虑数据的局部相似性,以保持测试样本与其相邻训练样本之间的相似性。结果 本文算法能得到一个闭式(closed-form),可避免稀疏表示分类算法中由于迭代引起的高时间复杂度问题,在 ORL、扩展 YALEB 和 PIE 人脸库上的识别率分别可达 91.4%、93.8% 和 93.2%,与同类算法相比识别率有较大幅度地提高;实验结果验证了算法所得到的系数具有较高的判别能力。结论 算法将训练样本进行奇异值分解得到“干净”的训练样本,能在一定程度上消除噪声的影响,且在协作表达的基础上,考虑测试样本和与之相邻的训练样本的局部相似性,相比原始的协作表达分类算法有更好的稳定性和鲁棒性。

关键词: 协作表达; 稀疏表示; 局部思想; 鲁棒性; 人脸识别

Locality constrained collaborative representation classification for robust classification

Lou Songjiang¹, Zhao Xiaoming¹, Yu Haitao², Zhang Shiqing¹

1. Institute of Image Processing & Pattern Recognition, Tai Zhou University, Taizhou 318000, China;

2. College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China

Abstract: **Objective** Sparse representation is a popular topic in computer vision and pattern recognition. This process first expresses the test sample as a linear combination of training samples. Sparse representation also determines the class that minimizes deviation for classification purposes. Recent advances in representation-based classification methods show that collaborative representation, rather than sparsity, improves face recognition accuracy. Unlike sparse representation, collaborative representation is computationally efficient and recognizes faces well. However, this performance degrades sharply if the training samples are corrupted by noise. This noise is very common in practical applications and causes side effects that destabilize classification results. Collaborative representation also ignores data locality, which is important. To address these two problems, a new algorithm for locality-constrained collaborative representation classification is proposed in this paper for robust categorization. **Method** Singular value decomposition is performed to remove noise in the training samples, and the training samples are approximated as the clean training samples. Local similarity is employed to maintain the simi-

收稿日期: 2014-11-26; 修回日期: 2015-02-12

基金项目: 国家自然科学基金项目(61272261, 61203257); 浙江省自然科学基金项目(LQ15F020001)

第一作者简介: 楼宋江(1982—), 男, 讲师, 2011 年于哈尔滨工程大学检测技术与自动化专业获得博士学位, 主要研究方向为计算机视觉和模式识别。E-mail: lousongjiangac@163.com

Supported by: National Natural Science Foundation of China (61272261, 61203257); Project supported by the Natural Science Foundation of Zhejiang Province, China (LQ15F0200012)

larity between the test sample and its adjacent training samples. Locality is an important characteristic in the reduction and classification of dimensionality because locality results in sparsity but not vice versa. **Result** The proposed algorithm can obtain a closed-form solution through collaborative representation and avoid the dilemma of expensive computations in sparse representation. This algorithm also considers local similarity. Experiments are conducted on ORL, Extended YALEB, and PIE face databases. Results demonstrated that the obtained coefficients display much discriminative power and that the proposed algorithm performs well. Moreover, recognition rates reach 91.4%, 93.8%, and 93.2% respectively. **Conclusion** The proposed algorithm simply and feasibly reduces the effect of noise in the training samples and obtains “clean” samples for representation-based classification. The proposed method measures dissimilarity by applying locality. This technique also suppresses the corresponding weight coefficient for distant samples while emphasizing the role of samples that are similar to the test sample in the training set. The test samples are represented as well. Experimental results demonstrate the feasibility and effectiveness of the algorithm. Thus, this method is a new technique for representation-based classification, such as face recognition, in that the side effects of noise on classification can be eliminated. This elimination is almost impossible for conventional methods.

Key words: collaborative representation; sparse representation; locality; robustness; face recognition

0 引言

模式分类是计算机视觉和模式识别中重要的研究领域,近年来也备受关注。随着数据的获取越来越容易,人类面临着数据洪流的困扰^[1]。模式分类的对象是数据表示,因此如何有效地表示数据是模式识别的重要课题,也是当前的研究热点之一。近年来,研究者相继提出很多数据表示方法,并广泛应用于模式识别和计算机视觉等领域。

Lee 等人提出了非负矩阵分解 NMF (non-negative matrix factorization) 算法^[2],通过寻找两个非负、低秩矩阵的乘积,非负矩阵分解以基向量线性组合来表示,具有较强的语义解释,能反映人类思维中的局部构成整体的思维。但是 NMF 的目标函数是非凸的,寻找全局最优解有一定的挑战,且其收敛性是一个研究难点。矩阵的广义低秩逼近 GLRAM (generalized low rank approximation of matrix)^[3]是近期提出的一种矩阵分解方法,算法对数据进行双向降维,来获得较高的压缩率,因此能节省较大的存储空间。稀疏编码 SC (sparse coding)^[4]也是近期提出的一种算法,在压缩传感 CS (compressive sensing)^[5]的基础上,以稀疏性为先验知识,即其大部分表示系数的绝对值很小,因此所得到的变换矩阵是稀疏的或者是接近稀疏的,相关研究者^[6]指出稀疏表达符合人类视觉系统中大脑 V1 区的稀疏表示机制。Zheng 等人在流形学习的基础上,提出了一种图正则化的稀疏表达算法 GRSC (graph regularized sparse cod-

ing)^[7],并应用于图像表示,通过增加流形约束项,使得在稀疏编码时考虑样本的流形几何结构。另外,Jiang 等人提出了 LC-KSVD (label consistent KSVD) 算法^[8],算法在学习字典时考虑样本的类别信息,使得保持样本类别信息的一致性。稀疏表达算法及其改进算法通过稀疏项得到最优解,但是算法需要对稀疏项采用交替迭代的方法进行求解,计算复杂度较高。

Zhang 等人指出,基于稀疏表示分类器有如此出色性能的原因,不是因为 L_1 -范数的稀疏约束,而是训练样本的协作表示 CR (collaborative representation)^[9],由此提出了协作表示分类器 CRC (collaborative representation classifier)。协作表示是通过 L_2 范数来代替 L_1 范数的稀疏项,能得到一个闭式解,无需迭代完成最优解,因此算法计算效率较高。类似的算法还有测试样本的二阶段稀疏表示 TPTSSR (two phase test sample sparse representation)^[10],线性回归分类器 LRC (linear regression classifier)^[11]等。

协作表达算法以测试样本的最小重构误差作为测试样本类别的判别依据,其误差在某种程度上可看做测试样本中的噪声,因此协作表达在一定程度上能处理测试样本中存在的噪声。但是基于表示的分类算法 (representation based classification) (包括稀疏表示和协作表达等) 未考虑训练样本中的噪声,即当训练样本也存在噪声时,算法对识别结果会产生较大影响^[12],并且算法未考虑数据的局部结构。一些文献^[13-14]指出局部性有时比稀疏性还

重要,因为局部性会导致稀疏性,而稀疏性不一定会导致局部性,因此将数据的局部性融入到稀疏表达算法中会得到更有效的稀疏表达系数。针对这两个问题,提出一种融合局部思想和协作表达的鲁棒分类算法并应用于人脸识别,算法一方面通过对训练样本进行奇异值分解,保留大部分能量,去除一些噪声;另一方面,算法通过在协作表达系数中增加局部性限制,以保持测试样本和与之相邻的训练样本的相似性,因此所得到的稀疏表示系数具有较强的判别信息。

1 稀疏表达和协作表达

假设有样本 $X = \{X_1, X_2, \dots, X_C\}$, 表示有 C 类样本, 其中 $X_i = \{x_1, x_2, \dots, x_{n_i}\}$ 表示由第 i 类样本组成的训练样本, n_i 表示第 i 类样本的个数, 设训练样本为 y 。

稀疏表示用尽可能少的基向量(训练样本)来线性表示测试样本, 表示系数向量为 a , 其模型可表示为

$$\min_a \|a\|_0 \text{ s.t. } y = Xa \quad (1)$$

式中, $\|\cdot\|_0$ 表示数据的 L_0 范数, 由于求解 L_0 范数是一个 NP 难问题, 但当所得的解足够稀疏时, 其等价于求解 L_1 范数^[15], 因此式(1)可以转换成

$$\min_a \|a\|_1 \text{ s.t. } y = Xa \quad (2)$$

当测试样本中存在一定噪声时, 假设误差为 ε , 可以把式(2)看成是以下优化问题, 即

$$\min_a \|a\|_1 \text{ s.t. } \|y - Xa\|_2 \leq \varepsilon \quad (3)$$

式(3)可以采用优化理论求解, 也可通过一些工具包求解, 比如 L_1 -magic^[16] 工具包, $l1$ -ls ($l1$ -regularized least squares)^[17] 工具包等。

其分类依据是测试样本在训练样本集中的最小重构误差所在的类别将作为测试样本的类别, 即

$$\text{identity}(y) = \arg \min_i \{ \|y - X_i a_i\|_2 \}, i = 1, 2, \dots, C \quad (4)$$

式中, a_i 表示第 i 类样本重构 y 时的系数向量。

稀疏表示通过表示系数向量的 L_1 范数稀疏项来实现, 但是 Zhang 等人指出真正起作用的是协作表达, 而不是 L_1 范数稀疏项。他们提出了基于协作表达的分类算法, 用 L_2 范数代替 L_1 范数。协作表达的框架为

$$\hat{a} = \arg \min_a \|y - Xa\|_2 + \lambda \|a\|_2 \quad (5)$$

通过正则化的最小二乘法求解, 得到其最优解为

$$\hat{a} = (X^T X + \lambda I)^{-1} X^T y \quad (6)$$

协作表达的原理与稀疏表达一样, 同样是以重构误差最小的类别作为测试样本的类别, 即

$$\begin{aligned} \text{identity}(y) = \\ \arg \min_i \{ \|y - X_i a_{i2}\| / \|a_i\|_2 \} \\ i = 1, 2, \dots, C \end{aligned} \quad (7)$$

实验结果表明, 协作表达分类器的识别性能与稀疏表达分类器较为接近, 且能较大程度地降低计算复杂度。

类似稀疏表示的误差表示形式, 式(5)误差表示形式为

$$\min_a \|a\|_2 \text{ s.t. } \|y - Xa\|_2 \leq \varepsilon \quad (8)$$

式中, ε 可看成是误差, 在某种程度上也可以看成是测试样本中的噪声。因此协作表达在一定程度上可以处理测试样本中的噪声, 但是当训练样本集 A 中存在噪声时, 算法性能会受到影响。且算法未能考虑样本之间的差异性, 即测试样本有可能会由与其较远的训练样本来重构, 在分类时有可能会分类到与其较远的类别中, 因此会导致算法的不稳定。

2 融合局部思想和协作表达的鲁棒分类算法

针对协作表达未考虑训练样本集中存在的噪声和未考虑测试样本与训练样本之间的相似性, 提出融合局部思想和协作表达的鲁棒分类算法。

假设有训练样本 $X = \{X_1, X_2, \dots, X_C\}$, 表示有 C 类样本, 其中 $X_i = \{x_1, x_2, \dots, x_{n_i}\}$ 表示由第 i 类样本组成的训练样本, n_i 表示第 i 类样本的个数, 设训练样本为 y 。为了处理训练样本集中的噪声, 先对训练样本进行奇异值分解, 即

$$X = U \Lambda V^T \quad (9)$$

式中, $U = \{u_1, u_2, \dots, u_d\}$, $V = \{v_1, v_2, \dots, v_d\}$, 对角阵 $\text{diag}(\Lambda) = [\lambda_1, \lambda_2, \dots, \lambda_d]$, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$, 其中 d 为样本的维数。然后对 X 进行部分重构, 保留大部分能量, 丢弃特征值较小的部分, 得

$$\hat{X} = \sum_{i=1}^k \lambda_i u_i v_i^T, k \leq d \quad (10)$$

式中, k 称为有效重构参数。则 $\hat{\mathbf{X}}$ 的第 i 列 $\hat{\mathbf{x}}_i$ 就是原始样本 $\mathbf{x}_i$ 的重构样本, 得到新的训练样本

$$\hat{\mathbf{X}} = \{\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_n\} = \{\hat{\mathbf{X}}_1, \hat{\mathbf{X}}_2, \dots, \hat{\mathbf{X}}_C\} \quad (11)$$

在原始的协作表达算法中, 测试样本有可能是由与其较远的训练样本来重构, 导致算法不稳定。因此, 对测试样本 $\mathbf{y}$ 在新的训练样本集 $\hat{\mathbf{X}}$ 进行协作表达分类时, 考虑其与相邻训练样本的相似性, 得

$$\hat{\mathbf{a}} = \arg \min_a \|\mathbf{y} - \hat{\mathbf{X}}\mathbf{a}\|_2 + \lambda \|\mathbf{w} \cdot \mathbf{a}\|_2 \quad (12)$$

式中, $\mathbf{w}$ 为差异度向量, 即如果测试样本 $\mathbf{y}$ 和训练集中第 i 类第 j 个样本 $\hat{\mathbf{x}}_{ij}$ 较远, 则 w_{ij} 较大, 以限制其表示系数的大小, 进而 $\hat{\mathbf{a}}_{ij}$ 会变小, 反之亦然。因此, 通过式(2), 可以将测试样本由与其较近的训练样本来表示, 限制与其较远的训练样本的贡献, 其表示系数有可能会接近于零, 从而表示系数中大部分是零而只有一小部分是 nonzero, 因此算法有效融合了数据的局部性和稀疏性。

由以上的分析可以看出 w_{ij} 正比于测试样本 $\mathbf{y}$ 与 $\hat{\mathbf{x}}_{ij}$ 之间的距离, w_{ij} 的一种可行表示方法为

$$w_{ij} = \text{dist}(\mathbf{y}, \hat{\mathbf{x}}_{ij}) = \|\mathbf{y} - \hat{\mathbf{x}}_{ij}\|_2 \quad (13)$$

接着对式(12)进行化简, 得

$$\begin{aligned} \hat{\mathbf{a}} &= \arg \min_a \|\mathbf{y} - \hat{\mathbf{X}}\mathbf{a}\|_2 + \lambda \|\mathbf{w} \cdot \mathbf{a}\|_2 = \\ &\text{tr}((\mathbf{y} - \hat{\mathbf{X}}\mathbf{a})(\mathbf{y} - \hat{\mathbf{X}}\mathbf{a})^T) + \lambda \text{tr}(\mathbf{w} \cdot \mathbf{a})(\mathbf{w} \cdot \mathbf{a})^T = \\ &\text{tr}(\mathbf{y}\mathbf{y}^T - 2\mathbf{y}\mathbf{a}^T\hat{\mathbf{X}}^T + \hat{\mathbf{X}}\mathbf{a}\mathbf{a}^T\hat{\mathbf{X}}^T + \lambda\mathbf{w}\mathbf{a}\mathbf{a}^T\mathbf{w}^T) \end{aligned} \quad (14)$$

对 $\mathbf{a}$ 求偏导得

$$\begin{aligned} \frac{d(\text{tr}(\mathbf{y}\mathbf{y}^T - 2\mathbf{y}\mathbf{a}^T\hat{\mathbf{X}}^T + \hat{\mathbf{X}}\mathbf{a}\mathbf{a}^T\hat{\mathbf{X}}^T + \lambda\mathbf{w}\mathbf{a}\mathbf{a}^T\mathbf{w}^T))}{d\mathbf{a}} &= \\ \frac{2\text{tr}(-\mathbf{y}^T\hat{\mathbf{X}} + \mathbf{a}^T\hat{\mathbf{X}}^T\hat{\mathbf{X}} + \lambda\mathbf{a}^T\mathbf{w}^T\mathbf{w})}{d\mathbf{a}} &= \\ 2(-\mathbf{y}^T\hat{\mathbf{X}} + \mathbf{a}^T\hat{\mathbf{X}}^T\hat{\mathbf{X}} + \lambda\mathbf{a}^T\mathbf{w}^T\mathbf{w}) &= \\ 2(-\mathbf{y}^T\hat{\mathbf{X}} + \mathbf{a}^T(\hat{\mathbf{X}}^T\hat{\mathbf{X}} + \lambda\mathbf{w}^T\mathbf{w})) \end{aligned} \quad (15)$$

将式(15)赋为0, 得到最优解

$$\hat{\mathbf{a}} = (\hat{\mathbf{X}}^T\hat{\mathbf{X}} + \lambda\mathbf{w}^T\mathbf{w})^{-1}\hat{\mathbf{X}}^T\mathbf{y} \quad (16)$$

然后根据协作表达分类原理, 测试样本的类别为

$$\begin{aligned} \text{identity}(\mathbf{y}) &= \\ \arg \min_i \{ \|\mathbf{y} - \hat{\mathbf{X}}_i\hat{\mathbf{a}}_i\|_2 / \|\hat{\mathbf{a}}_i\|_2 \} & \\ i = 1, 2, \dots, C \end{aligned} \quad (17)$$

综上, 本文算法可以描述为:

1) 对训练样本集 $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C\}$ 进行奇异值分解, 通过式(10)保留能量较大的部分, 得到新的训练样本集 $\hat{\mathbf{X}}$ 。

2) 对测试样本 $\mathbf{y}$ 由 $\hat{\mathbf{X}}$ 进行线性重构, 且考虑样

本的局部特性, 通过式(16), 得到其协作表达系数为

$$\hat{\mathbf{a}} = (\hat{\mathbf{X}}^T\hat{\mathbf{X}} + \lambda\mathbf{w}^T\mathbf{w})^{-1}\hat{\mathbf{X}}^T\mathbf{y}$$

3) 计算训练集中每一类样本重构 $\mathbf{y}$ 的误差, 如第 i 类样本重构 $\mathbf{y}$ 时的误差为

$$e_i(\mathbf{y}) = \|\mathbf{y} - \hat{\mathbf{X}}_i\hat{\mathbf{a}}_i\|_2 / \|\hat{\mathbf{a}}_i\|_2 \quad (18)$$

4) 测试样本的类别为 $e_i(\mathbf{y})$ 最小所属的类别, 即

$$\begin{aligned} \text{identity}(\mathbf{y}) &= \arg \min_i \{ e_i(\mathbf{y}) \} \\ i &= 1, 2, \dots, C \end{aligned} \quad (19)$$

3 实验结果及分析

为了验证算法的正确性和有效性, 分别在 ORL、扩展的 YALEB 和 PIE 人脸库上进行实验。经过多次实验进行比对, 实验过程中设置参数 $\lambda = 0.001$, 奇异值分解的有效重构参数 $k = d - 800$, 其中 d 为样本的维数。本文算法与 NN^[18]、SRC^[4]、TPTSSR^[9] 和 CRC^[10] 进行比较。

ORL 人脸库由 40 个人在不同的姿态、光照和表情等情况下拍摄的, 每个人拍摄 10 幅图像, 总共 400 幅人脸图像, 这些人脸图像在脸部表情和一些细节上有着不同程度的变化, 其姿态也有相当程度的变化。Extend-YALEB 人脸库由 38 个人在不同的实验室控制光照条件下拍摄的, 每人 64 幅图像, 总共 2 414 幅人脸图像。PIE 人脸库由 68 个人在不同光照、姿态等条件下拍摄, 共 41 368 幅图像, 由于人脸图像相对较多, 这里取每人 40 幅图像作为实验, 共 2 720 幅。因此这 3 个人脸库在人脸的面部表情、姿态和光照等方面均存在一定的差异, 能够很好地检验算法的鲁棒性。为了计算方便, 实验中, 所有图像均缩放为 32×32 像素, 并将人脸图像的像素值归一化为 $[0 - 1]$ 范围。图 1、图 2 和图 3 分别给出了以上 3 个人脸库的部分样本。



图1 ORL 人脸图像的样本

Fig. 1 Samples from ORL



图2 YALEB 人脸图像的样本
Fig. 2 Samples from YALEB



图3 PIE 库中部分人脸图像
Fig. 3 Samples from PIE

在 ORL 人脸库上进行实验时,随机选取每人中的 $l(l=3,4,5)$ 幅图像作为训练样本,剩下的作为测试样本。对于每个不同训练样本数,重复 20 次,最后取平均值作为最终识别结果。表 1 给出了 ORL 人脸库上各类算法在不同训练样本数下的识别率。

表 1 ORL 人脸库不同训练样本数对应的最高识别率

Table 1 Best recognition rates for different methods on ORL database

算法	/%		
	3 个训练样本	4 个训练样本	5 个训练样本
NN	68.9	76.8	82.4
SRC	79.8	86.2	88.7
TPTSSR	82.4	87.9	89.3
CRC	81.2	86.1	88.5
本文	85.6	89.2	91.4

在 YALEB 人脸库上进行实验时,由于其每个人的样本数较多,这里随机选取每人中的 $l(l=10,20,30)$ 幅图像作为训练样本,剩下的作为测试样本。对于每个不同训练样本数,重复 20 次,最后取平均值作为最终识别结果。表 2 给出了 YALEB 人脸库上各类算法在不同训练样本数下的识别率。

表 2 YALEB 人脸库不同训练样本数对应的最高识别率

Table 2 Best recognition rates for different methods on YALEB database

算法	/%		
	10 个训练样本	20 个训练样本	30 个训练样本
NN	54.7	75.2	87.5
SRC	81.4	87.8	91.8
TPTSSR	83.4	87.9	92.6
CRC	80.7	88.2	90.9
本文	85.8	88.4	93.8

在 PIE 人脸库上进行实验时,随机选取每人中的 $l(l=5,10,20)$ 幅图像作为训练样本,剩下的作为测试样本。对于每个不同训练样本数,重复 20 次,最后取平均值作为最终识别结果。表 3 给出了 PIE 人脸库上各类算法在不同训练样本数下的识别率。

表 3 PIE 人脸库不同训练样本数对应的最高识别率

Table 3 Best recognition rates for different methods on PIE database

算法	/%		
	5 个训练样本	10 个训练样本	20 个训练样本
NN	42.4	47.5	76.7
SRC	60.2	76.4	85.4
TPTSSR	68.1	82.6	89.8
CRC	62.4	78.7	87.5
本文	70.8	83.4	93.2

为了比较各类算法的时间复杂度,以 YALEB 人脸库为例(训练样本数为 10),在实验过程中记录算法的运行时间。实验环境为 Win XP 操作系统,联想 Intel Core (TM) 2 Duo CPU 2.20 GHz,内存 1 G。表 4 给出了各类算法在 YALEB 人脸库上的运行时间。

表 4 YALEB 人脸库各类算法的运行时间比较

Table 4 Computation time comparison for different methods on YALEB database

算法	/s	
	时间(训练样本数 10)	
NN	0.68	
SRC	10.10	
TPTSSR	0.95	
CRC	0.84	
本文	1.82	

从表 1、表 2 和表 3 可以看出:1) 本文算法的性能较 NN、SRC、TPTSSR 和 CRC 有较大幅度的提高,这有可能是因为本文算法将数据的局部相似性融入到协作表达中,且在训练样本中进行奇异值分解,这样一方面可以在求解协作表示系数的时候保持测试样本与训练样本之间的相似性,另一方面,通过奇异值分解,能有效处理训练样本中存在的一些噪声,因此所得到的系数具有较强的鲁棒性和含有更多的判

别性能。2) TPTSSR 算法通过两个阶段找出与测试样本最近的样本类, 然后进行分类。具体来讲, 算法先找出最能表示测试样本的训练集, 得到有效的训练样本空间, 然后在新的训练样本空间中根据每类样本对测试样本的贡献进行分类。算法通过第1阶段找出最能表示测试样本的训练样本, 其本质是找出与测试样本最近的训练样本, 其实质与本文所使用的局部思想是一致的, 即突出它们在表示测试样本中的地位, 因此识别率较 SRC 和 CRC 略有提高。3) 而 SRC 和 CRC 的识别率比 NN 高, 这是由于 SRC 和 CRC 都是基于表示的分类算法 RBC (representation-based classification), 选择出能有效表示测试样本的训练样本集及其表示系数, 然后根据每类的贡献大小, 找出能有效表示测试样本且其误差最小的类, 因此算法有较好的识别性能。从表4可以看出, 本文算法比稀疏表示算法 SRC 在计算时间上有较大幅度地下降, 这主要是由于稀疏表示算法 SRC 需要迭代求解, 而本文提算法能得到一个闭式 (closed-form), 计算相对有效。但是本文提算法需要通过奇异值求解以消除噪声的影响, 需要消耗一点时间, 比协作表达算法 CRC 计算时间稍长。

4 结 论

在协作表达和数据局部相似性的基础上, 提出了融合局部思想和协作表达的鲁棒分类算法。该算法的特点在于: 首先对训练样本进行奇异值分解, 以消除训练样本中存在的一些噪声; 然后在协作表达时, 算法通过数据的局部相似性以降低与测试样本较远的样本在重构测试样本时的贡献, 由此得到的系数更利于模式分类。但值得指出的是, 由于差异度向量的选择没有一个确定的理论依据, 因此, 如何更合理选择差异度向量以遏制与测试样本较远的训练样本在数据表示时的贡献是今后的一个研究内容。

参考文献 (References)

- [1] Baraniuk R G. More is less: signal processing and the data deluge[J]. Science, 2011, 331(6018): 717-719.
- [2] Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization[J]. Nature, 1999, 401(6755): 788-791.
- [3] Ye J. Generalized low rank approximations of matrices[J]. Machine Learning, 2005, 61(1-3): 167-191.
- [4] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
- [5] Candes E J, Wakin M B. An introduction to compressive sampling[J]. IEEE Signal Processing Magazine, 2008, 25(2): 21-30.
- [6] Olshausen B A, Field D J. Sparse coding with an overcomplete basis set: a strategy employed by V1? [J]. Vision research, 1997, 37(23): 3311-3325.
- [7] Zheng M, Bu J J, Chen C, et al. Graph regularized sparse coding for image representation[J]. IEEE Transactions on image processing, 2011, 20(5): 1327-1336.
- [8] Jiang Z L, Lin Z, Davis L. Learning a discriminative dictionary for sparse coding via label consistent K-SVD[C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2011: 1697-1704.
- [9] Zhang L, Yang M, Feng X C. Sparse representation or collaborative representation: which helps face recognition? [C] // Proceedings of IEEE International Conference on Computer Vision. Barcelona: IEEE, 2011: 471-478.
- [10] Xu Y, Zhang D, Yang J, et al. A two-phase test sample sparse representation method for use with face recognition[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2011, 21(9): 1255-1262.
- [11] Naseem I, Togneri R, Bennamoun M. Linear regression for face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106-2112.
- [12] Liu G C, Lin Z C, Yan S C, et al. Robust recovery of subspace structures by low-rank representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 171-184.
- [13] Yang J, Zhang L, Xu Y, et al. Beyond sparsity: the role of L1-optimizer in pattern classification[J]. Pattern Recognition, 2012, 45: 1104-1118.
- [14] Wang J, Yang J, Yu K, et al. Locality-constrained linear coding for image classification[C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. San Francisco: IEEE, 2010: 3360-3367.
- [15] Xu B, Yang J C, Yan S C et al. Learning with L1-Graph for image analysis[J]. IEEE Transactions on Image Processing, 2010, 19(4): 858-866.
- [16] Candes E, Romberg J. l1-magic: recovery of sparse signals via convex programming [EB/OL]. [2014-11-11]. <http://users.ece.gatech.edu/~justin/l1magic/>.
- [17] Kim S J, Koh K, Lustig M, et al. An interior-point method for large-scale l1-regularized least squares[J]. IEEE Journal of Selected Topics in Signal Processing, 2007, 1: 606-617.
- [18] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13: 21-27.