



基于稀疏化双向二维主成分分析的人脸识别

张裕平, 龚晓峰, 雒瑞森

(四川大学 电气工程学院, 成都 610065)

摘 要: 双向二维主成分分析((2D)²PCA)易受异常值影响,鲁棒性差,且所提取的特征向量是非稀疏的。针对上述不足,提出基于 L₁ 范数的稀疏双向二维主成分分析方法(2D)²PCA-L1S。在(2D)²PCA 目标函数中加入 L₁ 范数约束,以提高算法的抗干扰能力,同时引入弹性网约束,通过 Lasso 与 Ridge 惩罚函数实现稀疏性。在 Feret 和 Yale 数据库中进行基于最近邻的人脸分类、人脸重构和基于粒子群优化 SVM 参数的人脸识别实验,结果表明,相较于 2DPCA、(2D)²PCA、(2D)²PCA-L1 等主成分分析方法,该方法能准确提取人脸主要信息,人脸识别和人脸重构效果较好。

关键词: 双向二维主成分分析;稀疏化;粒子群优化;支持向量机;人脸识别

开放科学(资源服务)标志码(OSID):



中文引用格式:张裕平,龚晓峰,雒瑞森. 基于稀疏化双向二维主成分分析的人脸识别[J]. 计算机工程,2019,45(12):232-236.

英文引用格式:ZHANG Yuping, GONG Xiaofeng, LUO Ruisen. Face recognition based on sparse two-direction two-dimensional principle component analysis[J]. Computer Engineering, 2019, 45(12): 232-236.

Face Recognition Based on Sparse Two-Direction Two-Dimensional Principle Component Analysis

ZHANG Yuping, GONG Xiaofeng, LUO Ruisen

(College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

[Abstract] Two-Direction Two-Dimensional Principle Component Analysis((2D)²PCA) is an improved method of Principle Component Analysis(PCA) in the two-dimensional space. However, just like PCA, the (2D)²PCA is susceptible to abnormal values, its robustness is weak and the extracted feature vectors are non-sparse. So this paper proposes a sparse (2D)²PCA method based on L₁ norm, the (2D)²PCA-L1S, to tackle these problems. First, this paper adds the L₁ norm constraint to the (2D)²PCA objective function to improve the anti-interference ability. Then, this paper introduces the elastic network constraint into the objective function, so the sparsity is realized by the Lasso and Ridge penalty functions. The following experiments are carried out on the Feret and Yale datasets: the face classification and face reconstruction based on nearest neighbors, and the face recognition based on Particle Swarm Optimization(PSO)-SVM Parameters. The results show that compared with other PCA method, such as the 2DPCA, (2D)²PCA and (2D)²PCA-L1, the proposed method can accurately extract the main face information, and it has better effects on face recognition and face reconstruction.

[Key words] Two-Direction Two-Dimensional Principle Component Analysis((2D)²PCA); sparsity; Particle Swarm Optimization(PSO); Support Vector Machine(SVM); face recognition

DOI:10.19678/j.issn.1000-3428.0053108

0 概述

人脸识别作为人工智能研究的热点^[1-3],在人脸检测^[4]、身份鉴定^[5-6]等方面被广泛应用。特征提取

是人脸识别的基础,其经典方法主成分分析(Principle Component Analysis, PCA)^[7]将高维空间数据向样本方差最大的方向投影到低维空间,从而实现降维的目的。然而当样本协方差矩阵较大时,PCA 求解特

基金项目:中国博士后科学基金(2017M612958)。

作者简介:张裕平(1994—),女,硕士研究生,主研方向为图像处理、机器学习;龚晓峰,教授、博士;雒瑞森,讲师、博士。

收稿日期:2018-11-09 **修回日期:**2019-01-10 **E-mail:**892537951@qq.com

征值和特征向量较为困难。为此,文献[8]提出二维主成分分析(Two-Dimensional Principle Component Analysis, 2DPCA)法,其样本协方差矩阵只与图片尺寸有关,故相应的协方差矩阵较小,更易求解特征值和特征向量。进一步地,文献[9]提出双向二维主成分分析(Two-Direction Two-Dimensional Principle Component Analysis, (2D)²PCA)法,在图片的行列方向同时进行降维,得到的协方差矩阵更小,求解投影矩阵的速度更快。

由于PCA方法容易受到异常样本的影响,因此研究人员采用L₁范数对其约束,以提高算法的鲁棒性,代表方法有PCA-L1^[10]、2DPCA-L1^[11]、R1-PCA^[12]。但上述方法提取出的特征仍然是密集的特征,而研究人员希望从大量特征中选出最相关或者最突出的特征,以进一步精简模型。因此,文献[13]提出的稀疏建模受到广泛的关注,并有研究人员尝试将稀疏化理论运用于PCA,例如文献[14]提出稀疏的主成分分析方法(Sparse Principle Component Analysis, SPCA),文献[15]提出结构化SPCA,文献[16]证明了在L₁范数约束下SPCA的鲁棒性。

本文将基于L₁范数的SPCA推广到(2D)²PCA中,提出(2D)²PCA-L1S方法,采用L₁范数约束提高鲁棒性,并在目标函数中加入弹性网^[14]约束实现稀疏化。

1 鲁棒稀疏的(2D)²PCA方法

1.1 (2D)²PCA方法

(2D)²PCA可以直接对二维图像行和列2个方向同时进行降维,其协方差矩阵只与图片的尺寸有关,故协方差维数较小,求解投影矩阵较为容易。

设样本图片集 $X = \{x_1, x_2, \dots, x_N\}$, 每张图片的尺寸为 $m \times n$, 则训练样本行方向的协方差矩阵为:

$$G_r^r = \frac{1}{N} \sum_{i=1}^N (\bar{x}_i)^T (\bar{x}) \quad (1)$$

其中, $\bar{x}_i = x_i - \bar{x}$, $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ 。求取协方差矩阵 G_r^r 的前 p 个最大特征值对应的特征向量,组成行方向最佳投影方向 $X_{opt} = [X_1, X_2, \dots, X_p]$ 。同理,列方向的协方差矩阵为:

$$G_c^c = \frac{1}{N} \sum_{i=1}^N (\bar{x}_i) (\bar{x})^T \quad (2)$$

将协方差矩阵 G_c^c 的前 q 个最大特征值对应的特征向量,组成列方向的最佳投影方向 $Z_{opt} = [Z_1, Z_2, \dots, Z_q]$ 。获得图片在行和列上的投影矩阵之后,将尺寸为 $m \times n$ 的图片向这2个方向投影,得到 $q \times p$ 的特征矩阵:

$$c_i = Z^T x_i X, i = 1, 2, \dots, N \quad (3)$$

1.2 基于L₁范数的(2D)²PCA方法

基于L₂范数的(2D)²PCA在遇到异常值时表

现不稳定,而基于L₁范数的(2D)²PCA对异常值不敏感,具有较好的鲁棒性。假设 $v \in \mathbb{R}^p$ 是行方向协方差矩阵 $G_r^r \in \mathbb{R}^{n \times n}$ 第一大特征值对应的特征向量,找到最优 v^* 使得目标函数值最大。目标函数的数学描述如下:

$$g(v) = \sum_{i=1}^N \|x_i v\|_1, \text{ s. t. } \|v\|_2 = 1 \quad (4)$$

令 $x_{ji} \in \mathbb{R}^n$ 表示 x_i 的第 j 行向量,将 $g(v)$ 改写为:

$$g(v) = \sum_{i=1}^N \sum_{j=1}^m |v^T x_{ji}| \quad (5)$$

使用迭代算法寻得最优 v^* :

$$v(t+1) = \frac{\sum_{i=1}^N \sum_{j=1}^m s_{ji}(t) x_{ji}}{\left\| \sum_{i=1}^N \sum_{j=1}^m s_{ji}(t) x_{ji} \right\|_2} \quad (6)$$

$$s_{ji}(t) = \text{sign}(v^T(t) x_{ji}), j = 1, 2, \dots, m; i = 1, 2, \dots, N \quad (7)$$

迭代直至 $g(v)$ 收敛最大值。行方向投影矩阵中其余 $p-1$ 个特征向量和列方向投影矩阵的特征向量组也用同样的迭代方法求得。

1.3 基于L₁范数的稀疏化(2D)²PCA方法

基于L₁范数的(2D)²PCA方法,由于目标函数中没有权值惩罚项,求得投影矩阵的权重往往是非零且密集的,因此提取出的特征是样本所有特征的线性组合,具有冗余性且语义解释性差。弹性网正则化是惩罚函数Lasso与Ridge的线性组合,在这2项正则化约束下求得的投影矩阵是稀疏的,能将高度相关的特征一并选出,去除冗余成分^[17]。因此,本文提出基于L₁范数的稀疏化(2D)²PCA方法((2D)²PCA-L1S),在目标函数中引入弹性网来实现稀疏性,目标函数的表达式如下:

$$h(v) = \sum_{i=1}^N \sum_{j=1}^m |v^T x_{ji}| - \frac{\eta}{2} \|v\|_2^2 - \lambda \|v\|_1 \quad (8)$$

用迭代算法寻找最优的投影矩阵 v^* ,使 $h(v)$ 达到最大值。迭代算法以优化行方向投影矩阵为例,列方向投影矩阵寻优方法与行方向一致。

$$y(t) = \sum_{i=1}^N \sum_{j=1}^m s_{ji}(t) x_{ji} \quad (9)$$

$$w(t) = \left(\frac{|v_1(t)|}{\lambda + \eta |v_1(t)|}, \frac{|v_2(t)|}{\lambda + \eta |v_2(t)|}, \dots, \frac{|v_n(t)|}{\lambda + \eta |v_n(t)|} \right)^T \quad (10)$$

$v_k(t)$ 是特征向量 v 的第 k 个值:

$$v(t+1) = y(t) \circ w(t) \quad (11)$$

其中,运算符 \circ 表示2个向量的内积操作。算法迭代直至 $h(v)$ 收敛到最大值,行方向投影矩阵中其余 $p-1$ 个特征向量用同样的迭代方法求得。

2 基于粒子群优化的 SVM 参数优化

文献[18]提出的粒子群优化(Particle Swarm Optimization, PSO)算法求解参数少,收敛速度快,已广泛应用于模式识别领域。PSO 算法原理是随机产生一定数量的粒子群,每个粒子的位置都由适应度函数进行打分,根据分数选出每一种群里最优的粒子,再产生所有种群里最优的粒子,然后所有粒子的位置根据这 2 种最优粒子进行位置的迭代更新,目的是找到全局最优的位置。

因为 SVM 惩罚参数和核函数参数的取值对模型识别性能有着决定性的影响,所以本文利用 PSO 算法对 SVM 模型参数进行寻优。SVM 核函数选择径向基函数(Radial Basis Function, RBF),用粒子的 x 、 y 坐标值分别代表 SVM 惩罚参数 c 和核函数参数 g ,评价粒子位置的适应度函数由 n 折交叉验证下验证集的平均识别率表示,每一轮迭代在所有的粒子群中选出局部最优和全局最优,然后所有粒子的位置根据这 2 个最优值进行迭代更新,直到达到设置的期望适应度值或者最大迭代次数时停止迭代,这时全局最优粒子的坐标就是最优参数 c 和 g 的值,参数寻优流程如图 1 所示。

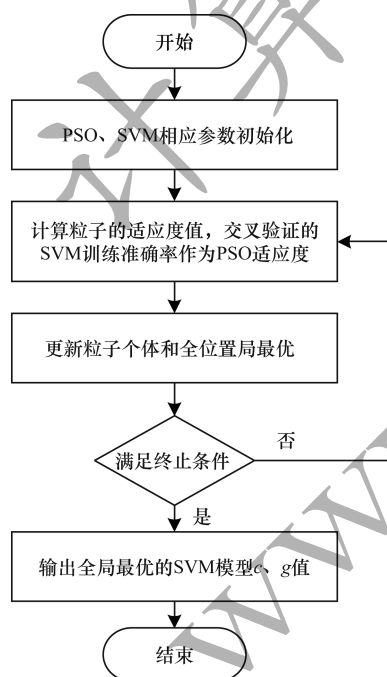


图 1 利用 PSO 优化 SVM 参数的流程

3 实验与结果分析

3.1 图像分类

实验采用 Feret 人脸库,该人脸库包含 200 人,每人 7 幅共 1 400 幅图像。本文采用最近邻分类器,随机选取每人 4 幅图像作为训练集,剩余 3 幅作为

测试集,分别利用 $(2D)^2$ PCA-L1S、PCA、2DPCA、 $(2D)^2$ PCA 和 $(2D)^2$ PCA-L1 方法提取人脸特征并进行人脸识别,实验结果如图 2 所示。

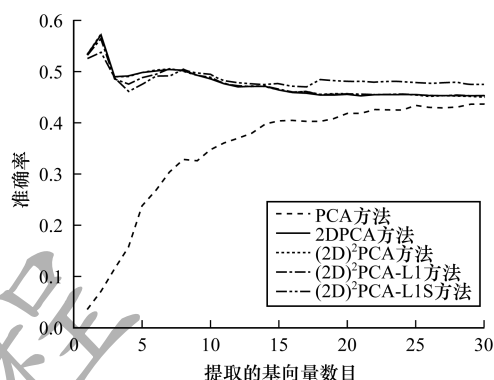


图 2 5 种方法分类准确率对比

从图 2 可以看出,当特征数持续增加时,PCA 方法的人脸识别率最低,其次是 2DPCA、 $(2D)^2$ PCA 和 $(2D)^2$ PCA-L1 方法,它们的识别曲线几乎重叠,而识别率最高的是 $(2D)^2$ PCA-L1S 方法。这说明在 5 种方法中,本文方法能更加精准地提取图像主要信息。

值得注意的是,在稀疏化的过程中,可调参数 $s = \lg(\eta/\lambda)$ 对算法的性能影响较大。为了验证该可调参数对识别性能的影响,实验观测 $(2D)^2$ PCA-L1S 方法在 $s = -3, -1, 0, 1, 3$ 时的人脸识别效果,结果如图 3 所示。结果显示:当 $s = -3$ 和 $s = -1$ 时,分类准确率随着特征数的增加呈现上升的趋势;而当 $s = 1$ 和 $s = 3$ 时,分类准确率随着特征数的增加呈现下降的趋势。在实际应用中,可以根据需求来选择不同的 s 值以满足稀疏化和识别准确率的要求。

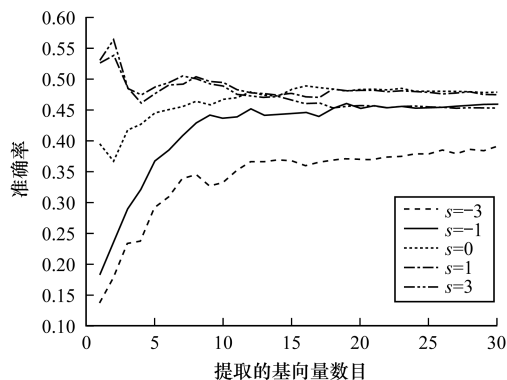


图 3 不同稀疏化参数对本文方法识别效果的影响

3.2 图像重构

实验选择 Yale 人脸库,该人脸库包含 15 人,每人 11 幅共 165 幅图像,每幅图像大小为 100 像素 \times 100 像素。随机在 20% 的图像中添加矩阵噪声,添加了噪声的异常图像如图 4 所示。



图 4 包含噪声的图像

对噪声污染的 Yale 数据集, 分别采用 PCA、2DPCA、 $(2D)^2$ PCA、 $(2D)^2$ PCA-L1 和 $(2D)^2$ PCA-L1S 方法进行图像重建, 计算图像重建的平均误差, 结果如图 5 所示。

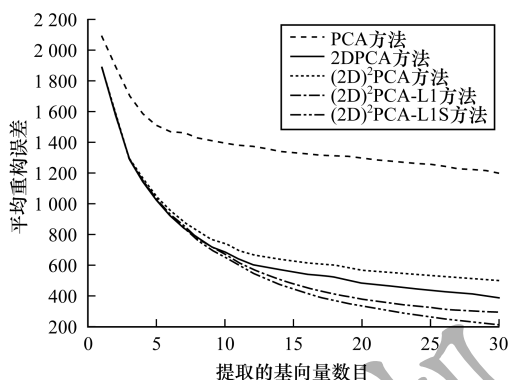


图 5 5 种方法重构图像的平均误差曲线

从图 5 可以看出, 随着特征数的增加, 各算法的平均误差均持续下降, $(2D)^2$ PCA-L1S 算法的平均重构误差明显小于其他方法的平均重构误差。 $(2D)^2$ PCA-L1 曲线数值明显低于 $(2D)^2$ PCA 曲线, 说明基于 L_1 范数的方法能提高算法的鲁棒性, 抗噪声干扰能力增强; $(2D)^2$ PCA-L1S 曲线数值低于 $(2D)^2$ PCA-L1 曲线, 说明引入稀疏化能增强特征选择的能力。实验还给出了 $(2D)^2$ PCA-L1S 方法中不同的稀疏化参数 s 取值对图像重构效果的影响, 结果如图 6 所示。随着 s 值的增加, 图像重构的平均误差呈现下降趋势, 当 $s=3$ 时图像重构效果最好。

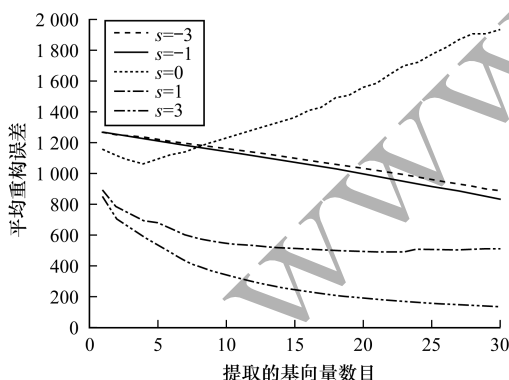


图 6 不同稀疏化参数下本文方法的平均重构误差

3.3 基于 PSO 算法 SVM 参数优化的人脸识别

实验选择 Yale 人脸库, 人脸库包含 15 人, 每人 11 幅共 165 幅图像, 每幅图像大小为 100 像素 \times 100 像素。PSO 算法的惩罚参数 c 和 RBF 参数 g 均设置为 $(0, 100]$ (经验值 c 为 2, g 为 $1/k$, k 为数据样

本维数), 搜索参数 $c_1 = 1.6$, $c_2 = 1.5$, 权重系数 $w = 1$, 种群数量为 50, 最大迭代数为 50, PSO 的适应度函数由 5 折交叉验证下验证集识别率的平均值表示。实验随机选取每人 6 幅图像作为训练集, 剩余 5 幅作为测试集。在每次迭代过程中始终对最佳适应度和平均适应度进行比较, 确保得到的参数优化结果是全局最优的。图 7 为本文方法在双向维度降至 30×30 时, 经过 PSO 算法优化 SVM 参数得到的最佳适应度和粒子群的平均适应度。

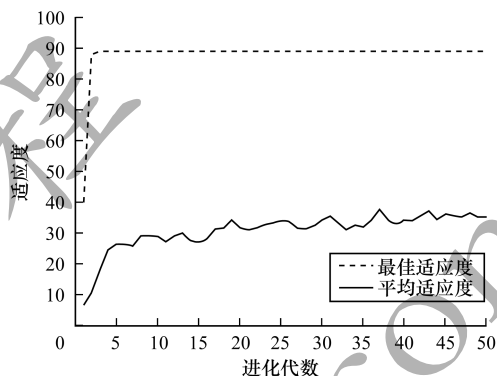


图 7 经 PSO 算法优化后本文方法的适应度

从图 7 可以看出, 当 PSO 进化到约 4 代时, 适应度达到最佳。而平均适应度始终远低于最佳适应度, 这说明经 PSO 算法优化后的参数更佳, 避免了参数取值陷入局部最优。

表 1 为经 PSO 优化参数 c 和 g 后的 SVM 模型识别率, 表 2 为依据经验选取参数 c 和 g 的 SVM 模型识别率。对比表 1 和表 2, 经过 PSO 优化参数的 SVM 模型识别率明显高于参数经验取值的 SVM 模型识别率, 表明经 PSO 优化地模型泛化能力更好。

表 1 基于 PSO 优化 SVM 参数的人脸图像识别性能

维数	c	g	训练集识别率 / %	测试集识别率 / %
5×5	5.065 50	0.233 5	75.56	88.00
10×10	3.537 20	0.014 8	82.22	93.33
15×15	5.653 30	0.005 8	86.67	94.67
20×20	2.031 00	0.016 9	90.00	92.00
25×25	0.891 22	12.395 3	82.22	93.33
30×30	4.443 60	7.631 2	88.89	94.67

表 2 SVM 取经验值时的人脸图像识别性能

维数	c	g	测试集识别率 / %
5×5	2	$1/25$	74.67
10×10	2	$1/100$	84.00
15×15	2	$1/255$	84.00
20×20	2	$1/400$	89.33
25×25	2	$1/625$	82.67
30×30	2	$1/900$	86.67

4 结束语

针对 $(2D)^2PCA$ 算法对异常值敏感、抗干扰性差以及特征向量不具有稀疏性的问题,本文提出一种基于 L_1 范数的稀疏 $(2D)^2PCA$ 方法,不仅提高了算法的鲁棒性,而且使稀疏化后的特征具有较好的语义解释性。人脸图像的识别和重构以及基于PSO算法优化SVM参数的识别实验结果,均验证了本文算法的有效性。由于本文实验所采用的人脸数据集规模较小,因此下一步将扩大实验数据集,同时改进PSO算法优化SVM参数的过程,以加强粒子搜寻空间能力。

参考文献

- [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] YU Qiang, WANG Rong, YANG Xiaojun, et al. Diagonal principal component analysis with non-greedy L_1 -norm maximization for face recognition [J]. Neurocomputing, 2016, 171: 57-62.
- [3] WANG Haixian. Block principal component analysis with L_1 -norm for image analysis [J]. Pattern Recognition Letters, 2012, 33(5): 537-542.
- [4] ZENG Dingheng, ZHONG Huicai. An incremental learning face detection algorithm oriented to wireless video browsing [J]. Journal of Chinese Computer Systems, 2014, 35(6): 1357-1357. (in Chinese)
曾定衡, 钟汇才. 面向无线视频浏览的增量学习人脸检测算法研究 [J]. 小型微型计算机系统, 2014, 35(6): 1357-1357.
- [5] ZHANG Jianming, LIU Yangchun, WU Honglin. Face recognition algorithm based on extreme learning machine and subspace pursuit [J]. Computer Engineering, 2016, 42(1): 168-173. (in Chinese)
张建明, 刘阳春, 吴宏林, 等. 基于极限学习机与子空间追踪的人脸识别算法 [J]. 计算机工程, 2016, 42(1): 168-173.
- [6] ZHANG Caixia, HU Hongping, BAI Yanping. Face recognition method based on sparse subspace clustering [J]. Fire Control and Command Control, 2017, 42(4): 29-32. (in Chinese)
张彩霞, 胡红萍, 白艳萍. 基于稀疏子空间聚类的人脸识别方法 [J]. 火力与指挥控制, 2017, 42(4): 29-32.
- [7] JOLLIFFE I T. Principal component analysis [M]. Berlin, Germany: Springer, 1986.
- [8] YANG Jian, ZHANG D, FRANGI A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [9] ZHANG Daoqiang, ZHOU Zhihua. $(2D)^2PCA$: two-directional two-dimensional PCA for efficient face representation and recognition [J]. Neurocomputing, 2005, 69(1/2/3): 224-231.
- [10] KE Qifa, KANADE T. Robust L_1 -norm factorization in the presence of outliers and missing data by alternative convex programming [C]//Proceedings of 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2005: 739-746.
- [11] LI Xuelong, PANG Yanwei, YUAN Yuan. L_1 -norm-based 2DPCA [J]. IEEE Transactions on Systems, 2009, 40(4): 1170-1175.
- [12] DING C, ZHOU Ding, HE Xiaofeng, et al. R1-PCA: rotational invariant L_1 -norm principal component analysis for robust subspace factorization [C]//Proceedings of the 23rd International Conference on Machine Learning. New York, USA: ACM Press, 2006: 281-288.
- [13] WRIGHT J, MA Yi, MAIRAL J, et al. Sparse representation for computer vision and pattern recognition [J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.
- [14] ZOU Hui, HASTIE T, TIBSHIRANI R. Sparse principal component analysis [J]. Journal of Computational and Graphical Statistics, 2006, 15(2): 265-286.
- [15] JENATTON R, OBOZINSKI G, BACH F. Structured sparse principal component analysis [J]. Journal of Machine Learning, 2009, 9(2): 131-160.
- [16] MENG Deyu, ZHAO Qian, XU Zhongben. Improve robustness of sparse PCA by L_1 -norm pattern recognition [J]. Pattern Recognition, 2012, 45(1): 487-497.
- [17] ZOU Hui, HASTIE T. Regularization and variable selection via the elastic net [J]. Journal of the Royal Statistical Society, 2005, 67(2): 301-320.
- [18] KENEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of IEEE International Conference on Neural Networks. Washington D. C., USA: IEEE Press, 1995: 1942-1948.

编辑 刘盛龄