



基于局部强化最小二乘回归分类法的人脸识别方法

简彩仁, 夏靖波*

(厦门大学嘉庚学院, 福建漳州, 363105)

摘要:为解决基于表示理论的分类法未考虑噪声样本对重构系数影响的不足,利用局部约束协同表示法改进最小二乘回归分类法,提出局部强化最小二乘回归分类法.该方法通过非负稀疏表示自适应选择近邻样本,并利用近邻样本的协同作用强化重构系数使得局部强化最小二乘回归分类法具有较好的鲁棒性和容噪性.该方法可以克服传统分类方法存在的过拟合问题.在4个人脸图像数据集上的实验表明该方法可以提高人脸识别准确率.

关键词: 人脸识别; 最小二乘回归; 局部强化; 自适应; 分类

中图分类号: TP 311, TP 371 **文献标识码:** A

Face recognition using local strengthen least square regression classification method

JIAN Cai ren, XIA Jing bo

(Tan Kah kee College, Xiamen University, Zhangzhou, 363105, China)

Abstract: In order to improve the weakness that the classification method based on the representation theory did not take into account about the influence of noise on the reconstruction coefficients, local strengthen least square regression classification method is proposed to improve the least square regression classification method by using the local-constraint cooperative representation. The proposed method will adaptively select its neighboring samples through nonnegative sparse representation, to strengthen the construction coefficient, which makes the local strengthen least square regression classification method has better robustness and anti-noise ability. This method can overcome the overfitting problem existing in traditional classification methods. The experimental results on the four face recognition datasets show that this method can improve the recognition accuracies.

keywords: face recognition; least square regression; local strengthen; adaptive ; classification

人脸识别是人工智能研究的重要分支,是一种应用广泛的模式识别技术^[1-4].例如视频监控、考勤签到、刷脸支付和访问控制等.因此人脸识别已经引起人们的浓厚兴趣.然而,在无约束环境下由设备拍摄的图像通常质量有限.各种人类面部表情、姿势和照明条件会影响面部图像的质量,导致出现标准化面部图像中的遮挡等问题,此外高维度特征空间或欠采样数据集使得人脸识别任务更具挑战性.因此,尽管已经提出了一些识别方法^[4-8],但仍然需要具有更高识别性能的鲁棒人脸识别方法.因此有必要进行深入的人脸识别研究.

传统的分类方法,比如支持向量机(SVM),需要训练分类器,容易造成过拟合问题^[9].而基于表示理论的分类方法^[6,10-14]不需要训练分类器,可以避免过拟合问题,因此在图像识别、基因表达数据分类等方面得到了广泛的应用.稀疏表示(SR)分类法^[6]是一种正则 L_1 范数的基于表示理论的方法.该方法利用SR方法用训练样本重构测试样本,利用 L_1 范数的稀

收稿日期: 2018-09-19 录用日期: 2018-10-24

基金项目: 福建省自然科学基金项目(2018J01101)

*通信作者: jbxia@xujc.com.



疏性质构建基于 SR 的分类器.许多类似的基于表示理论的分类方法被提出,比如非负最小二乘 (NNLS) 分类法^[10]通过非负约束达到重构系数的稀疏性,进而构建具有稀疏功能的分类器;而最小二乘回归 (LSR) 分类法^[11]通过正则 L_2 范数达到重构系数的聚集性,进而构建具有聚集功能的分类器.但是训练样本中可能存在大量的噪声样本,而这些样本会影响重构系数的计算.SR、NNLS 和 LSR 等在计算重构系数时,直接利用所有的训练样本进行计算并没有考虑噪声样本的影响.简彩仁等^[12]提出基于 SR 和 LSR (SRLSR) 分类法从剔除噪声样本的角度研究基因表达数据的识别问题,表明噪声样本确实会影响识别准确率.

以上的分析表明噪声样本会影响重构系数的计算;进而影响识别准确率.远离测试样本的训练样本更有可能是噪声样本,因此加强测试样本附近的训练样本对重构系数的协同作用,可以提高重构系数抵抗噪声的能力.基于此,本研究提出局部强化 LSR (local strengthen LSR, LSLSR) 分类法.该方法利用非负稀疏表示自适应选择近邻样本并通过近邻样本的协同作用强化重构系数使得 LSLSR 分类法具有更好的鲁棒性和容噪性.因此,LSLSR 可以强化重构系数的表示能力,进而提高识别准确率.

1 相关工作

本节给出 LSLSR 分类法提出的理论依据.

1.1 基于表示理论的重构系数求解方法

假设 $\mathbf{y} \in \mathbf{R}^{m \times 1}$ 是未知类别标签的人脸图像测试样本, $\mathbf{X} \in \mathbf{R}^{m \times n}$ 是已知类别标签的人脸图像训练样本集,有 n 个样本和 m 个图像属性,其中 $m \gg n$.用已知类别标签的人脸图像训练样本集 \mathbf{X} 重构未知类别标签的人脸图像测试样本 \mathbf{y}

$$\mathbf{y} \approx \sum_{i=1}^n \mathbf{x}_i \omega_i = \mathbf{X}\boldsymbol{\omega}, \quad (1)$$

其中, \mathbf{x}_i 为第 i 个训练样本, $\boldsymbol{\omega}$ 为重构系数.因为 $m \gg n$, 式 (1) 是一个超定方程, 求解其精确解没有意义.

为此, 提出 LSR 模型

$$\min_{\boldsymbol{\omega}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\omega}\|_2^2, \quad (2)$$

不难得到该问题的解析解

$$\boldsymbol{\omega} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}. \quad (3)$$

基于 LSR 模型, 文献[11]中构建了 LSR 分类法.

对重构系数 $\boldsymbol{\omega}$ 进行非负约束, 得到 NNLS 模型

$$\min_{\boldsymbol{\omega}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\omega}\|_2^2, \text{ s.t. } \boldsymbol{\omega} \geq 0, \quad (4)$$

即文献[10]中提出 NNLS 分类法的理论依据.

根据正则项的不同, 改变正则范数可以得到如下的稀疏表示问题

$$\min_{\boldsymbol{\omega}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\omega}\|_2^2 + \lambda \|\boldsymbol{\omega}\|_1, \quad (5)$$

其中, $\|\boldsymbol{\omega}\|_1$ 是向量 $\boldsymbol{\omega}$ 的 L_1 范数, 即向量 $\boldsymbol{\omega}$ 非零元素绝对值之和.文献[15]给出了一种快速计



算上述稀疏表示模型的方法.文献[6]利用该模型提出 SR 分类法.

1.2 最近邻子空间准则

最近邻子空间准则^[6]利用重构系数 ω 分类重构测试样本 y 的方法对测试样本进行分类.假设人脸图像数据集有 d 个类别 $\{l_1, l_2, \dots, l_d\}$, 对一个人脸图像测试样本 y 求解重构系数 ω , 对每一个类计算如下的度量余量

$$r_k(y) = \|y - X\delta_k(\omega)\|_2^2, \quad (6)$$

其中, $\delta_k(\omega): \mathbf{R}^n \rightarrow \mathbf{R}^n$ 计算得到类 l_k 的系数, 其第 j 个元素定义为

$$(\delta_k(\omega))_j = \begin{cases} \omega_j, & x_j \in l_k, \\ 0, & x_j \notin l_k. \end{cases} \quad (7)$$

最后, 根据重构误差最小的原则对测试样本 y 进行归类, 即测试样本 y 所属类别为

$$l = \arg \min_{1 \leq k \leq d} r_k(y). \quad (8)$$

2. LLSLR 算法

针对 SR、NNLS 和 LSR 等在计算重构系数时没有考虑噪声样本影响的不足, 借鉴最近邻子空间准则的思想, 通过强化局部近邻样本对重构系数 ω 的影响, 本研究提出 LLSLR.

2.1 目标函数

最小二乘回归方法也称为岭回归, 其经典模型^[11]为

$$\min_{\omega} \|y - X\omega\|_2^2 + \lambda \|\omega\|_2^2, \quad (9)$$

其中, $\lambda > 0$ 是正则参数.直接用训练样本 X 重构测试样本 y , 容易受到噪声样本的影响.

针对这一不足, 强化局部近邻样本对最小二乘回归方法的影响, 提出局部强化最小二乘回归模型如下,

$$\min_{\omega} (1 - \gamma) \|y - X\omega\|_2^2 + \gamma S_L + \lambda \|\omega\|_2^2, \quad (10)$$

其中, S_L 是局部强化项, 代表局部近邻样本对最小二乘回归方法的影响, $0 \leq \gamma < 1$ 是平衡参数, 用于平衡样本重构项和局部强化项.当 $\gamma = 0$ 时, 退化为岭回归模型.借鉴最近邻子空间准则, 定义局部强化项为

$$S_L = \frac{1}{k} \sum_{b_i \in N(y)} \|b_i - X\omega\|_2^2, \quad (11)$$

其中, $b_i \in N(y)$ 是样本 y 的近邻样本, k 是近邻样本的个数, S_L 刻画了局部近邻样本对重构系数的影响.由此, 得到如下的目标函数

$$\min_{\omega} (1 - \gamma) \|y - X\omega\|_2^2 + \gamma \frac{1}{k} \sum_{b_i \in N(y)} \|b_i - X\omega\|_2^2 + \lambda \|\omega\|_2^2, \quad (12)$$

其中, 式 (12) 的第一项是样本重构项, 第二项是局部强化项, 最后一项是岭回归惩罚项.

2.2 目标函数求解

本节研究目标函数的求解, 令目标函数为 $O(\omega)$, 不难得到



$$\begin{aligned}
 O(\omega) &= (1-\gamma)\|y - X\omega\|_2^2 + \gamma \frac{1}{k} \sum_{b_i \in N(y)} \|b_i - X\omega\|_2^2 + \lambda \|\omega\|_2^2 = \\
 &= (1-\gamma)\text{tr}((y - X\omega)^T (y - X\omega)) + \gamma \frac{1}{k} \sum_{b_i \in N(y)} \text{tr}((b_i - X\omega)^T (b_i - X\omega)) \\
 &+ \lambda \text{tr}(\omega^T \omega) = \\
 &= (1-\gamma)\text{tr}(y^T y) + \text{tr}(\omega^T X^T X \omega) - 2(1-\gamma)\text{tr}(\omega^T X^T y) \\
 &+ \gamma \frac{1}{k} \sum_{b_i \in N(y)} \text{tr}(b_i^T b_i) - 2\gamma \frac{1}{k} \sum_{b_i \in N(y)} \text{tr}(\omega^T X^T b_i) + \lambda \text{tr}(\omega^T \omega),
 \end{aligned} \tag{13}$$

其中, $\text{tr}(X)$ 为矩阵 X 的迹, 表示矩阵 X 主对角线元素的和, 这里应用了 $\text{tr}(X) = \text{tr}(X^T)$ 和 $\text{tr}(XY) = \text{tr}(YX)$. 对 ω 求导得

$$\frac{\partial O(\omega)}{\partial \omega} = 2X^T X \omega - 2(1-\gamma)X^T y + 2\lambda \omega - 2\gamma \frac{1}{k} \sum_{b_i \in N(y)} X^T b_i, \tag{14}$$

令 $\frac{\partial O(\omega)}{\partial \omega} = 0$, 得

$$\omega = (X^T X + \lambda I)^{-1} X^T \left((1-\gamma)y + \gamma \frac{1}{k} \sum_{b_i \in N(y)} b_i \right). \tag{15}$$

2.3 自适应近邻样本选择

为了避免 LSLSR 方法参数过多的问题, 采用自适应参数选择方法, 通过下式求解非负稀疏表示问题的重构系数 ω ,

$$\min_{\omega} \|y - X\omega\|_2^2 + \lambda \|\omega\|_1, \text{ s.t. } \omega \geq 0, \tag{16}$$

并取满足条件: $\omega > \text{mean}(\omega)$ 的样本为近邻样本.

2.4 LSLSR 算法流程

对每个样本求解重构系数 ω , 最后利用最近邻子空间准则对测试样本进行分类. 如下为 LSLSR 算法流程.

输入: 训练样本集 X , 测试样本 y , 训练样本类别 l_{train} , 正则参数 λ , γ

输出: 测试样本类别 l_{test}

- 1 标准化训练样本集 X 的每个样本和测试样本 y , 使每个样本具有单位 L_2 范数;
- 2 利用式 (16) 选择近邻样本;
- 3 利用式 (15) 求解重构系数 ω ;
- 4 利用 1.2 节的最近邻子空间准则对测试样本 y 分类, 得到测试样本类别 l_{test} .

3. 实验分析

3.1 实验数据与实验参数设置

本节通过实验验证 LSLSR 分类法的有效性, 对比方法有 SRLSR 分类法、SR 分类法、LSR 分类法、NNLS 分类法和 K 最近邻 (KNN) 分类法.

实验参数设置如下: SR 分类法和 LSLSR 分类法的正则参数 λ 设为 0.01, LSLSR 分类法的平衡参数 γ 设为 0.5; 实验采用交叉验证的方法对比各种分类方法的识别准确率, 交叉验证的折数取为 4~10 折.

实验选用广泛应用在人脸识别研究中的 4 个人脸图像数据集: FERET、PIE、ORL 和



Yale 进行研究,各数据集的基本信息如下

表 1 数据信息

Tab.1 Data information

数据集	维数	样本数	类别数	来源
FERET	1 024	280	40	http://www.nist.gov/itl/iad/ig/colorferet.cfm
PIE	1 024	400	20	http://www.datatang.com/data/11957
ORL	1 024	400	40	http://www.datatang.com/data/13501
Yale	1 024	165	15	http://cvc.yale.edu/projects/yalefaces/yalefaces.html

3.2 实验结果与分析

图 1 给出了在不同交叉验证折数下不同方法的识别准确率,表 2 给出了在不同交叉验证折数下不同方法的平均识别准确率.

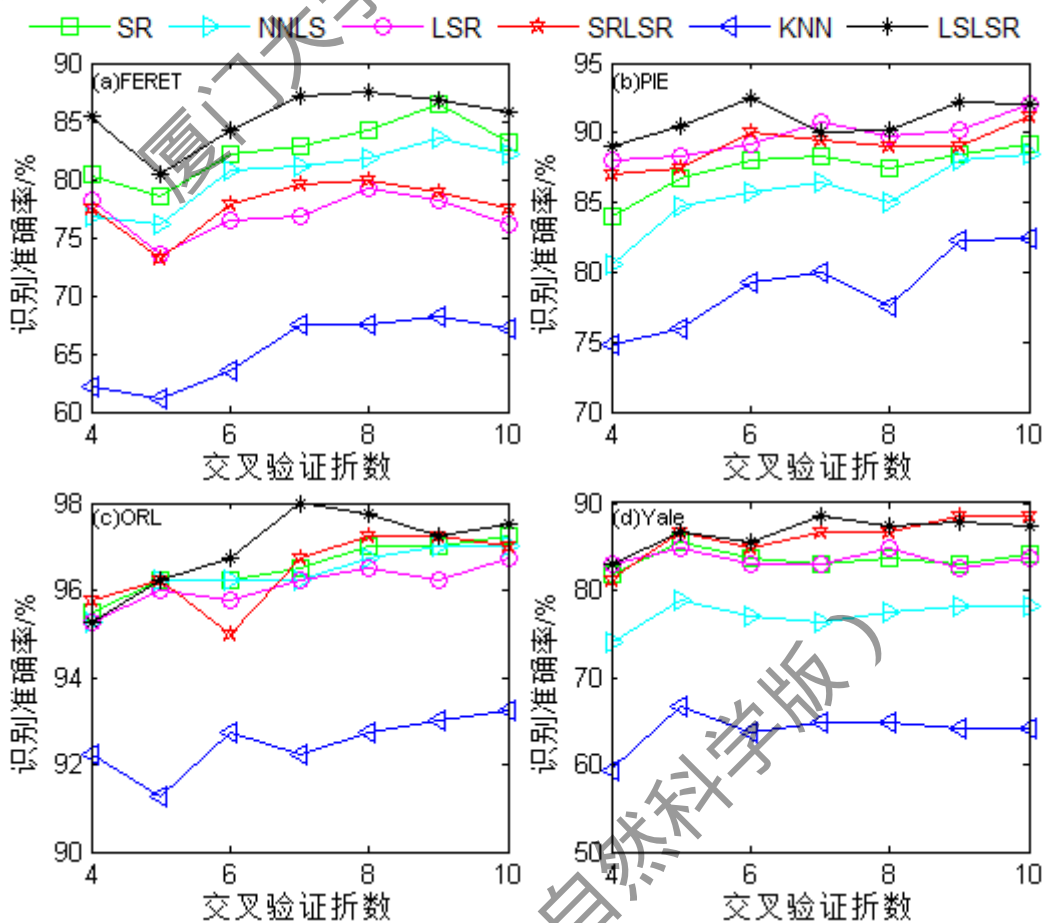


图 1 不同交叉验证折数下的人脸识别准确率

Fig.1 Face recognition accuracies under different cross-validation folds

表 2 平均人脸识别准确率

Tab.2 Average face recognition accuracies

数据集	SR	NNLS	LSR	SRLSR	KNN	LSLSR
FERET	82.55	80.31	76.94	77.81	65.31	85.31
PIE	87.46	85.57	89.75	89.04	78.89	90.93
ORL	96.54	96.39	96.11	96.46	92.50	96.96



Yale 83.55 77.14 83.55 86.15 63.98 **86.58**

图1直观地对比了各种方法在不同交叉验证折数下的识别能力.LLSLR在FERET、PIE、Yale和ORL等数据集上的识别准确率有明显的优势.LLSLR的识别准确率明显高于其他基于表示理论的识别方法(SR、NLS、LSR、SRLSR).图1和表2的实验结果表明LLSLR的平均准确率是最高的.这一结果表明LLSLR通过强化近邻样本的协同作用可以提高抗噪能力,具有很好的鲁棒性,可以强化重构系数的表示能力,从而提高人脸识别准确率.

从实验结果不难发现KNN的识别准确率是最低的,这反映了基于表示理论的分类方法可以有效地避免过拟合问题.

3.3 参数分析

本节讨论LLSLR分类法的不同的平衡参数 γ 对识别准确率的影响,实验结果如图2.

从图2的实验结果不难发现,不同 γ 值的识别准确率是不同的,这说明局部强化项对识别准确率有显著影响.实验结果显示,当 γ 取值在0.3~0.5的范围内,有较好的识别准确率.因此选择合适的 γ 值,即合适的平衡参数 γ 平衡样本重构项和局部强化项,对识别准确率有积极影响.

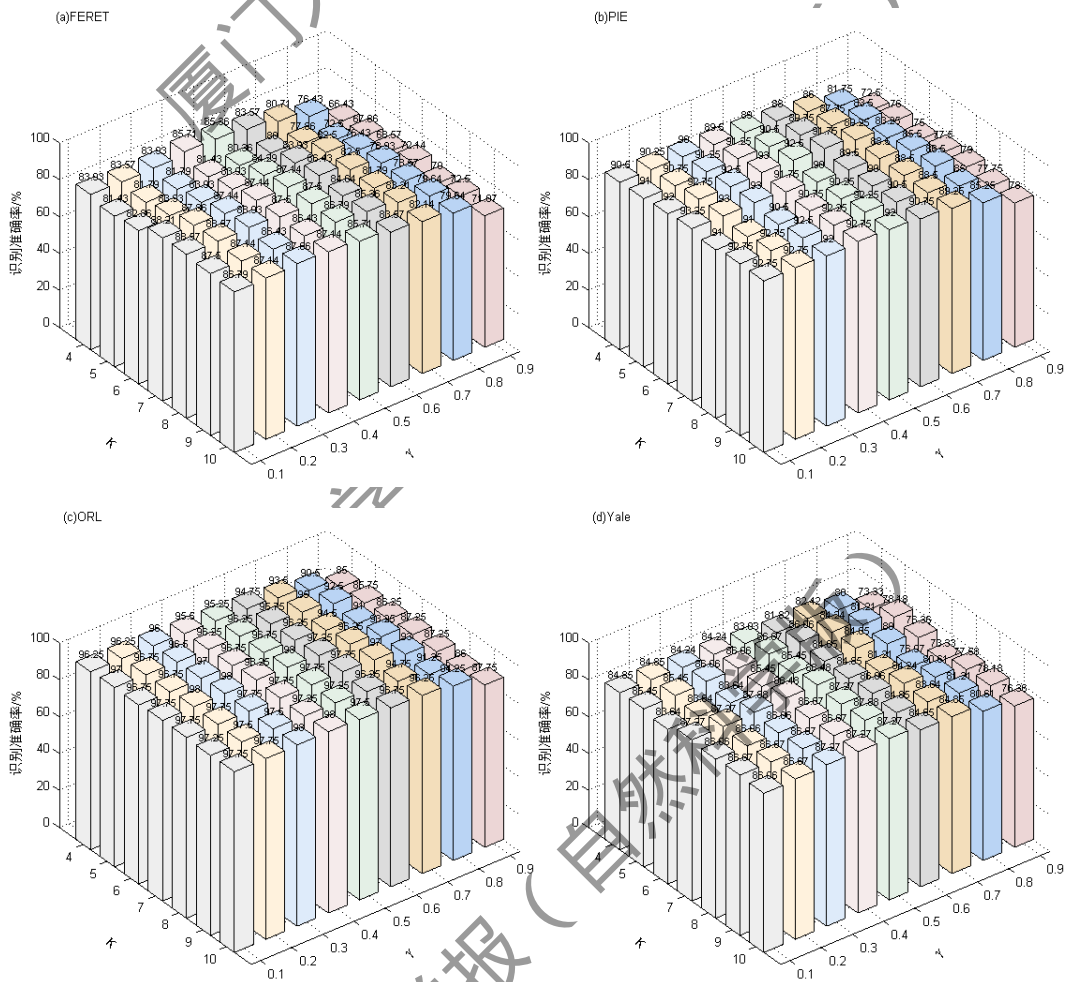


图2 不同 γ 下的人脸识别准确率

Fig.2 Face recognition accuracies under different γ

4. 结论

本研究提出 LLSLR 分类法,该方法通过加强近邻样本的作用达到减少噪声样本影响的目的.在4个常用的人脸图像数据集上的实验表明该方法可以明显地提高人脸识别准确率.本



研究提出基于非负稀疏表示的自适应近邻样本选择方法可以避免近邻样本数量的选择.由于存在选择近邻样本的步骤, LSLSR 的运行时间开销比较大, 如何更高效地剔除噪声样本将在以后的研究中给出.

参考文献

- [1]TOLBA A S, EL-BAZ A H, EL-HARBY A A A. Face recognition: a literature review[J]. *International Journal of Signal Processing*, 2008, 2(1):88-103.
- [2]吴长虹,苏剑波,陈叶飞.抗年龄干扰的人脸识别[J]. *电子学报*, 2018,46(7):1593-1600.
- [3]严严,陈日伟,王菡子.基于深度学习的人脸分析研究进展[J].*厦门大学学报(自然科学版)*,2017,56(1):13-24.
- [4]GAO Y, MA J, YUILLE A L. Semi-supervised sparse representation based classification for face recognition with insufficient labeled samples[J]. *IEEE Transactions on Image Processing*, 2017, 26(5):2545-2560.
- [5]雷明仪,苏松志,李绍滋.卡口场景下人脸检测模型的自适应重训练算法[J].*厦门大学学报(自然科学版)*,2017,56(3):429-436.
- [6]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.
- [7]任梓涵,杨双远.基于视觉跟踪的实时视频人脸识别[J].*厦门大学学报(自然科学版)*,2018,57(3):438-444.
- [8]付晓峰,张予,吴俊.遮挡表情变化下的联合辅助字典学习与低秩分解人脸识别[J]. *中国图象图形学报*, 2018, 23(3):399-409.
- [9]周志华.机器学习[M].北京:清华大学出版社,2016:121-139.
- [10]LI Y, NGOM A. Classification approach based on non-negative least squares[J]. *Neurocomputing*, 2013, 118(11):41-57.
- [11]CHEN X, JIAN C. A tumor classification model using least square regression[C]// *International Conference on Natural Computation*. Xiamen: ICNC 2014:753-758.
- [12]简彩仁,陈晓云.基于稀疏表示和最小二乘回归的基因表达数据分类方法[J]. *福州大学学报(自然科学版)*, 2015, 43(6):738-741.
- [13]LIN G, YANG M, YANG J, et al. Robust, discriminative and comprehensive dictionary learning for face recognition[J]. *Pattern Recognition*, 2018, 81(9):341-356.
- [14]GOU J, XU Y, ZHANG D, et al. Two-phase linear reconstruction measure-based classification for face recognition[J]. *Information Sciences*, 2018, 4(433):17-36.
- [15]KIM S J, KOH K, LUSTIG M, et al. An interior-point method for large-scale l_1 -regularized least squares[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2007, 1(4): 606-617.