

联合低秩和 ℓ_p 稀疏约束矩阵回归的人脸识别算法

杨国亮 罗 璐 鲁海荣 丰义琴 梁礼明

(江西理工大学电气工程与自动化学院 赣州 341000)

摘 要 针对遮挡和光照等因素影响的人脸图像,提出一种具有低秩稀疏性的矩阵回归模型。该模型采用低秩性约束回归误差,采用 ℓ_p 范数约束回归系数使其达到稀疏最大化,然后通过广义迭代阈值算法求解 ℓ_p 范数,最后用交替方向法求解模型参数。在 AR 和 Extended Yale B 人脸数据库上的实验表明,与当前的回归算法相比,该算法具有更高的识别率,能够更好地消除由遮挡引起的结构性噪声,且对光照变化也具有更强的鲁棒性。

关键词 人脸识别,核范数, ℓ_p 范数,广义迭代阈值算法,鲁棒回归,交替方向乘法

中图法分类号 TP391.41 文献标识码 A

Face Recognition Based on Matrix Regression with Low-rank and ℓ_p Sparse Constraints

YANG Guo-liang LUO Lu LU Hai-rong FENG Yi-qin LIANG Li-ming

(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract This paper presented a model of matrix regression for face recognition to deal with varying illumination, as well as occlusion and disguise. To ensure low rank and sparse prosperities of the model, we used low rankness to constraint the regression error, and used the ℓ_p -norm to constraint the regression coefficients in order to guarantee the sparsest solution. We applied generalized iterated shrinkage algorithm for ℓ_p -norm, and alternating direction method for regression coefficients. Experiment results on face database of AR and Extended Yale B show that the face recognition method proposed in this paper has a higher recognition rate than the current regression methods. And our method is more powerful for removing the structural noise caused by occlusion, and more robust for alleviating the effect of illumination.

Keywords Face recognition, Nuclear norm, ℓ_p -norm, Generalized iterated shrinkage algorithm, Robust regression, Alternating direction method of multipliers

1 引言

近年来,人脸识别作为模式识别的研究热点之一,在视频监控、身份验证等领域的应用越来越广泛。但在实际生活中,人脸图像往往受遮挡及光照变化等因素影响,导致其局部特征缺失,影响整体的识别效果。针对此问题,有很多学者提出了一系列行之有效的方法。2009年 J. Wright 等^[1]提出一种基于稀疏表示的人脸识别方法 SRC (Sparse Representation-based Classification),该方法将人脸识别看作多个线性回归模型的综合问题,解决了人脸识别的关键问题:特征提取和对遮挡的鲁棒性。字典由训练图像组成,测试图像由训练图像的线性组合来重构,重构系数是稀疏的,最小重构误差所对应的类别即为测试图像的类别。SRC 分类器在一些标准人脸数据库上获得了很好的识别率。随后, J. Yang 等在 SRC 的基础上提出两种基于 ℓ_1 范数的分类器^[2],该分类器在处理大样本问题时比 SRC 表现出更强的鲁棒性,计算效率更高,分类效果更好。在 SRC 中,测试样本是由训练样本的线性组合来重构的,稀疏表示的保真度由 ℓ_1 范数或者 ℓ_2 范数的余项来

表示,然而这种假设要求余项服从高斯分布,在实际中当测试样本存在噪声、遮挡和伪装等异常因素时这种分布不一定成立,这就导致传统的保真度表达式所构成的稀疏表示模型对上述情况缺少足够的鲁棒性。随后, M. Yang 等^[3]提出一种最大似然稀疏表示识别模型,将保真度表达式改写为余项的最大似然分布函数,并将最大似然问题转化为一个加权优化问题,在稀疏表示中引入能够代表各像素不同权值的矩阵,使得该算法对包含异常像素的图像表现出很好的鲁棒性。稀疏项一般是描述数据的局部信息,当数据受到较大污染时,稀疏算法的准确性就下降了。E. Candes 等人^[4]提出鲁棒主成分分析 (Robust Principal Component Analysis, RPCA), 其将样本矩阵分解为一个低秩逼近矩阵和一个稀疏误差矩阵,很好地解决了数据矩阵补全和恢复问题。然而, RPCA 模型假设观测数据的结构是一个低秩的线性子空间,而实际上许多数据分布于多个子空间的并集中,且数据点与某个子空间的关系也未知,因此, Liu G 在 RPCA 的基础上引入字典,提出一种低秩表示模型^[5] LRR (Low Rank Representation), 其具有良好的数据全局结构描述能力,对噪声也具有很好的鲁棒性。

本文受国家自然科学基金项目(51365017, 61305019),江西省科技厅青年科学基金(20132bab211032)资助。

杨国亮(1973—),男,博士,副教授,主要研究方向为模式识别与图像处理、智能控制, E-mail: ygliang30@126.com; 罗璐(1988—),女,硕士,主要研究方向为模式识别与图像处理; 鲁海荣(1989—),男,硕士,主要研究方向为模式识别与图像处理; 丰义琴(1989—),女,硕士,主要研究方向为模式识别与图像处理; 梁礼明(1967—),男,硕士,教授,主要研究方向为机器学习。

随后,有研究者提出在 LRR 的基础上引入数据空间约束项,构建具有揭示数据全局结构能力和鉴别能力的低秩图^[6],在谱图嵌入理论框架下对人脸图像进行识别。I. Nasceem^[7]提出一种线性回归分类器 (Linear Regression Classification, LRC) 用于人脸图像分类,该设计思想来源于最近子空间分类器,利用重构残差最小的原则进行识别。随后, Huang 等人^[8]将核方法引入 LRC 中,克服了光照变化下的低分辨率人脸图像识别问题。目前的回归分析法大多是利用基于误差图像的一维像素点信息,这种模型假设误差像素点服从独立同一分布,但在实际遮挡中,这种假设不一定成立,并且这种算法忽略了图像数据结构的全局信息。鉴于此,本文提出一种联合低秩和 ℓ_p 稀疏的矩阵回归模型,采用低秩性约束回归误差图像,采用 ℓ_p 范数约束回归系数使其达到稀疏最大化,最后用交替方向法计算模型参数。

2 联合低秩和 ℓ_p 稀疏约束矩阵回归的人脸识别算法

为了保证最小的 ℓ_1 范数能够更加接近最稀疏解,要求在很严格的不连贯条件。相比之下,使用 ℓ_p 范数的非凸最小化在较弱的不连贯条件和图像受较大噪声影响的情况下能保证较好的矩阵恢复效果,且 ℓ_p 范数能够克服全局都采用一种范数的缺点。因此,本文提出使用 ℓ_p 正则项来替代 ℓ_1 正则项,达到去除遮挡的目的。

2.1 基于核范数的矩阵回归模型

假设图像矩阵 $A_1, A_2, \dots, A_n \in R^{m \times n}$, 测试图像矩阵 $B \in R^{m \times n}$, 则 B 可由 A 线性表示:

$$B = x_1 A_1 + x_2 A_2 + \dots + x_n A_n + E \quad (1)$$

其中, x_1, x_2, \dots, x_n 代表回归系数, E 代表误差项。若定义 $A(x) = x_1 A_1 + x_2 A_2 + \dots + x_n A_n$, 则 B 可表示为:

$$B = A(x) + E \quad (2)$$

用相应的线性向量回归问题^[9]代替式(2)可写为:

$$Vec(B) = x_1 Vec(A_1) + \dots + x_n Vec(A_n) + E \quad (3)$$

其中, $Vec(B)$ 是把矩阵 B 转换为向量的转换符。

采用 F 范数计算回归系数,如下:

$$\min \|A(x) - B\|_F^2 \quad (4)$$

其中, $A(x) - B$ 是误差图像。通常情况下误差图像(块状遮挡)相对于原图像具有低秩性,因此把式(4)改写为:

$$\min rank \|A(x) - B\| \quad (5)$$

秩函数是非凸不连续的函数,而核范数是秩函数的紧致凸包络,故采用最小化核范数来优化秩最小化问题^[9],如下所示:

$$\min \|A(x) - B\|_* \quad (6)$$

2.2 基于低秩稀疏约束的矩阵回归模型

在很多关于图像修复和分类的稀疏编码问题中,采用非凸 ℓ_p ($0 \leq p < 1$) 范数最小化往往能够获得比凸 ℓ_1 范数更好的效果,因为 ℓ_p 范数比 ℓ_1 范数更接近稀疏解,因此本文采用 ℓ_p 范数约束回归系数,具体模型如下:

$$\begin{cases} \min_x \|A(x) - B\|_* + \lambda \|x\|_p^p \\ \text{subject to } A(x) - B = Y \end{cases} \quad (7)$$

其中, λ 是权重参数,设定为 $\lambda = 1/\sqrt{\max(m, n)}$ 。采用非精确增广拉格朗日乘子法^[10,11] (Inexact Augmented Lagrange Multipliers, IALM) 求解模型(7)。为把模型(7)转化为可分离凸优化问题,可引入辅助变量 Y , 且 $Y = A(x) - B$, 其增广

拉格朗日函数如下:

$$\begin{aligned} L_\mu(x, Y, Z) &= \|Y\|_* + \lambda \|x\|_p^p + \langle Z, A(x) - B - Y \rangle + \\ &\quad \frac{\mu}{2} \|A(x) - B - Y\|_F^2 \\ &= \|Y\|_* + \lambda \|x\|_p^p + \frac{\mu}{2} \|A(x) - B - Y + \\ &\quad \frac{Z}{\mu}\|_F^2 \end{aligned} \quad (8)$$

其中, μ 是惩罚因子,确保算法收敛性, Z 为拉格朗日乘子。利用交替更新的方法求解问题式(8),先固定 Y 和 Z 求解 x , 再固定 x 和 Z 求解 Y , 最后固定 x 和 Y 求解 Z , 即通过迭代求解如下 3 个子问题,得到模型的最优解。

$$x_{k+1} = \arg \min_x L_\mu(x_k, Y_k, Z_k) \quad (9a)$$

$$Y_{k+1} = \arg \min_Y L_\mu(x_{k+1}, Y_k, Z_k) \quad (9b)$$

$$Z_{k+1} = Z_k + \mu_k (A(x_{k+1}) - B - Y_{k+1}) \quad (9c)$$

2.2.1 回归系数 x 的求解

为求解子问题(9a),令:

$$H = [Vec(A_1), \dots, Vec(A_n)] \quad (10)$$

$$g = Vec(B + Y - \frac{Z}{\mu}) \quad (11)$$

其中, $Vec(A_i)$ 表示把矩阵 A_i 转换成列向量的转换符,因此可以用 Hx 代替 $A(x)$, 其中 $A(x) = \sum_{j=1}^n x_j A_j$, x 求解如下:

$$\begin{aligned} x_{k+1} &= \arg \min_x L_\mu(x_k, Y_k, Z_k) \\ &= \arg \min_x (\lambda \|x_k\|_p^p + \frac{\mu_k}{2} \|A(x) - (B + Y_k - \frac{Z_k}{\mu_k})\|_F^2) \\ &= \arg \min_x \lambda \|x_k\|_p^p + \frac{\mu_k}{2} \|Hx - g\|_F^2 \end{aligned} \quad (12)$$

对于子问题(12)中的 ℓ_p 范数,文献^[12]指出 3 种经典的求解算法,分别是迭代加权 ℓ_1 最小化 (Iteratively Reweighted ℓ_1 minimization, IRL1)、迭代加权最小二乘法 (Iteratively Reweighted Least Squares, IRLS) 和迭代阈值法 (Iteratively Thresholding Method, ITM)。其中 IRL1 和 IRLS 能够求解有约束和无约束问题,而 ITM 只能求解无约束问题。IRL1 和 IRLS 的设计思想非常相似,然而它们的求解方法却截然不同,IRL1 和 IRLS 分别是通过采用一系列加权 ℓ_1 项和加权 ℓ_2 项来近似 ℓ_p 范数。其中 IRLS 可以通过阈值迭代收敛于一个稀疏解,然而这个阈值很难选取得当,因此会导致算法本身可能不包含零元素。IRL1 和 IRLS 的收敛条件相当苛刻,且上述 3 种方法不能保证收敛于全局最优解,所以本文采用文献^[13]提出的广义迭代阈值算法 (Generalized Iterated Shrinkage Algorithm, GISA)。该算法是对软阈值算子的一个扩展,可以用于解决非凸 ℓ_p 范数稀疏编码问题,其具有坚实的理论基础,能够获得比以上 3 种方法更精确的解,且算法易于实现。因此子问题(12)可写成如下形式:

$$\begin{aligned} x_{k+1} &= \arg \min_x L_\mu(x_k, Y_k, Z_k) \\ &= \arg \min_x \lambda \|x_k\|_p^p + \frac{\mu_k}{2} \|Hx - g\|_F^2 \\ &= T_p^{GST}(x_k - \|H\|^{-2} H^T (Hx - g); \|H\|^{-2} \frac{\lambda}{\mu}) \end{aligned} \quad (13)$$

式中, T_p^{GST} 为软阈值算子,定义如下:

$$T_p^{GST}(y; \lambda) = \begin{cases} 0, & \text{if } |y| \leq \tau_p^{GST}(\lambda) \\ \text{sgn}(y) S_p^{GST}(|y|; \lambda), & \text{if } |y| > \tau_p^{GST}(\lambda) \end{cases} \quad (14)$$

采用 T_p^{GST} 算子求解 ℓ_p 范数, 要解决两个问题: (1) 计算软阈值 $\tau_p^{GST}(\lambda)$; (2) 快速搜索非零解。

其中参数 p 和 λ 之间存在的阈值 $\tau_p^{GST}(\lambda)$ 定义如下:

$$\tau_p^{GST}(\lambda) = (2\lambda(1-p))^{\frac{1}{2-p}} + \lambda p (2\lambda(1-p))^{\frac{p-1}{2-p}} \quad (15)$$

如果 $y < \tau_p^{GST}(\lambda)$, 那么 $x=0$ 是全局最小值, 否则非零解就是最优解。

根据文献[13]可知, S_p^{GST} 可通过如下方程求解:

$$S_p^{GST}(y; \lambda) - y + \lambda p (S_p^{GST}(y; \lambda))^{p-1} = 0 \quad (16)$$

求解式(16)的解析解不方便, 为此采用算法 1 求解其近似解。GST 的具体求解步骤如算法 1 所示。

算法 1(GST) $T_p^{GST}(y; \lambda) = \text{GST}(y, \lambda, p, J)$

输入: y, λ, p, J

$$1. \tau_p^{GST}(\lambda) = (2\lambda(1-p))^{\frac{1}{2-p}} + \lambda p (2\lambda(1-p))^{\frac{p-1}{2-p}}$$

$$2. \text{ if } |y| \leq \tau_p^{GST}(\lambda)$$

$$3. T_p^{GST}(y; \lambda) = 0$$

4. else

$$5. k=0, x_k = |y|$$

6. Iterate on $k=0, 1, \dots, J$

$$7. x_{k+1} = |y| - \lambda p (x_k)^{p-1}$$

8. $k \leftarrow k+1$

$$9. T_p^{GST}(y; \lambda) = \text{sgn}(y) x_k$$

10. end

输出: $T_p^{GST}(y; \lambda)$

文献[13]指出, 在求解 T_p^{GST} 算子时迭代次数为 2 或者 3 时结果最佳。

2.2.2 低秩矩阵 Y 的求解

求解 Y , 采用奇异值分解, 那么子问题(9b)则可以写成如下形式:

$$\begin{aligned} Y_{k+1} &= \arg \min_Y L_\mu(x_{k+1}, Y_k, Z_k) \\ &= \|Y_k\|_* + \frac{\mu_k}{2} \|A(x_{k+1}) - B - Y_k + \frac{Z_k}{\mu_k}\|_F^2 \\ &= D_{1/\mu_k}(A(x_{k+1}) - B + \frac{Z_k}{\mu_k}) \\ &= US_{1/\mu_k}(\Sigma)V^T \end{aligned} \quad (17)$$

其中, $A(x_{k+1}) - B + \frac{Z_k}{\mu_k} = U\Sigma V^T$, 软阈值算子^[14] $S_{1/\mu_k}(x) =$

$$\max(|x_{ij}| - \frac{1}{\mu_k}, 0) \text{sgn}(x_{ij}).$$

2.2.3 拉格朗日乘子 Z 的求解

对矩阵 Z 进行更新:

$$Z_{k+1} = Z_k + \mu_k (A(x_{k+1}) - B - Y_{k+1}) \quad (18)$$

综上可以归纳模型(7)的求解算法, 具体步骤如算法 2 所示。

算法 2 联合低秩 ℓ_p 稀疏约束矩阵回归模型的 IALM 算法

输入: 训练矩阵 A , 测试矩阵 B , 参数 $\lambda > 0, p \in (0, 1), g, J, \mu$

1. 初始化: 归一化矩阵 A 和矩阵 B , $x_0, Z_0 = 0, \mu_0 = 0.3, \rho_0 = 1.035,$
 $t = \|H\|^{-2}$

2. While not converged do

$$3. \begin{cases} x_{k+0.5} = x_k - tH^T(Hx_k - g) \\ x_{k+1} = \text{GST}(x_{k+0.5}, \frac{t\lambda}{\mu}, p, J) \end{cases}$$

$$4. Y_{k+1} = D_{1/\mu_k}(A(x_{k+1}) - B + \frac{Z_k}{\mu_k})$$

$$5. Z_{k+1} = Z_k + \mu_k (A(x_{k+1}) - B - Y_{k+1})$$

$$6. \mu_{k+1} = \min(\rho\mu_k, \mu_0)$$

7. end while

输出: 系数 x

2.3 分类器设计

参照文献[9], 本文设计的分类器如下: 假设测试样本 B 可由所有的训练样本 $A_1, A_2, \dots, A_n \in R^{m \times n}$ 表示, 那么通过求解模型 $\hat{x} = \arg \min_x \|A(x) - B\|_* + \lambda \|x\|_p^p$ 可以得到重构

图像 $\hat{B} = A(\hat{x})$, 残差图像 $E = B - \hat{B}$ 。现实生活中, B 一般会受噪声污染(比如光照和局部遮挡等), E 可以揭示重构信息。令 δ_i 是与第 i 类样本关联的系数, $\delta_i(x)$ 是第 i 类包含非零元素的向量, 可以得到 B 对应于第 i 类的重构图像 $\hat{B}_i = A(\delta_i(x))$, 更进一步, 可以得到 \hat{B} 与 \hat{B}_i 类关联重构误差为:

$$e_i(B) = \|\hat{B} - \hat{B}_i\|_* = \|A(\hat{x}) - A(\delta_i(\hat{x}))\|_* \quad (19)$$

基于重构误差, 给出的分类规则如下: 如果 $e_k(B) = \min_i e_i(B)$, 那么 B 就属于第 k 类。

3 实验结果与分析

本文在 AR 和 Extended Yale B 两个数据库上做实验。文献[12]指出, 当参数 p 取 0.5 时识别效果最佳, 所以本文算法分别取 p 为 1 和 0.5 这两个值, 再与 SRC、LRC、RSC 3 种算法的实验结果进行对比分析, 以验证本文算法对受到遮挡和光照影响的人脸图像的鲁棒性。

3.1 AR 数据库

AR 数据库包含 126 个人(70 个男人和 56 个女人), 每个人的图像包含不同的脸部表情、光照和遮挡情况, 每个人 26 张图像, 这些图像是分两个时期采集的(间隔两个星期), 每个时期 13 张, 包含 3 张墨镜遮挡和 3 张围巾遮挡, 剩余 7 张是在不同光照条件和不同姿势下采集的。AR 库中某个人的一部分人脸图像如图 1 所示。



图 1 AR 库中的某个人的一部分人脸样本

本文选取 AR 库中的 120 个人(65 个男人和 55 个女人), 实验选取每人 8 张图像作为训练样本, 6 张墨镜遮挡和 6 张围巾遮挡分别作为测试样本, 将所有图像大小裁剪为 50×40 。

为了更直观地体现本文算法的有效性, 做了误差分析实验。图 2 是通过算法将遮挡图像分解为低秩部分和误差部分的示意图。



图 2 利用本文算法对 AR 库遮挡图像的恢复结果

前两张测试图像是现实生活中戴墨镜和围巾遮挡的, 后一张图像是人为添加大小为 25×25 、遮挡面积为原图像 30%

的块状遮挡。从图中可以看出,本文算法能够较好地恢复出“干净”人脸图像。

3.1.1 真实人脸图像遮挡(墨镜)实验

在做墨镜遮挡实验时,选取参数 $\lambda=12$, 惩罚因子 $\mu=0.3$, 实验结果如图 3 所示。




图 3 墨镜遮挡测试效果

从图 3 中可以看出,当遮挡物为墨镜时,本文算法与其他 3 种算法相差不大,都得到了较高的识别率,当参数 p 取 0.5 时,本文算法识别率为 97.6%,比 RSC 高出 7.9 个百分点。

3.1.2 真实人脸图像遮挡(围巾)实验

在做围巾遮挡实验时,选取 $\lambda=8$, 惩罚因子 $\mu=0.1$, 实验结果如图 4 所示。

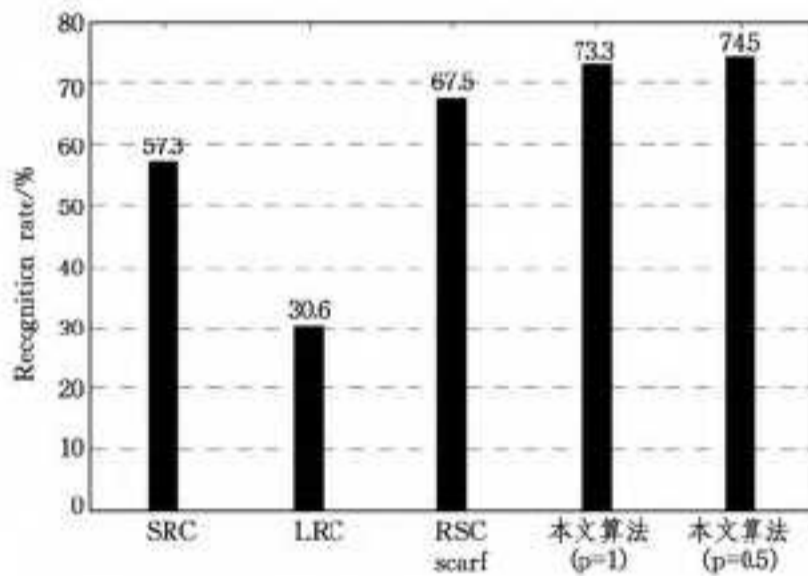


图 4 围巾遮挡测试效果

从实验结果可以看出,当遮挡物为围巾时,本文算法的优势比较明显,当参数 p 取 0.5 时,识别率为 74.5%,比 LRC 高出近 44 个百分点。

以上两组实验验证了本文算法对人脸受到真实遮挡时的鲁棒性。

3.2 Extended Yale B 数据库

Extended Yale B 数据库包含 38 个人在 9 种姿势和 64 种不同光照条件的图像,每个人的 64 张图像都是在特定的姿势下以 30 帧/s 的相机帧速度采集的,所以仅在头部姿势和面部表情有微小变化。Extended Yale B 库中一个人的部分人脸图像如图 5 所示。



图 5 Extended Yale B 库中一个人在不同光照下的人脸样本

在 Extended Yale B 库中,同样做误差观测分析,如图 6 所示。



图 6 利用本文算法对 Yale B 库遮挡图像的恢复结果

这两张测试图像都是采取人为添加块状遮挡的方式,前者是随机噪声,后者是“狒狒”图像,大小为 50×48 , 遮挡面积为原图像的 30%。从图 6 中亦可以看出,本文算法能够较好地恢复出“干净”人脸图像。

本文选取 Extended Yale B 库中的 38 个人,每人 8 张图像作为训练样本,测试样本分为 4 个子集,分别是人为添加不同程度遮挡的随机噪声、块状遮挡和“狒狒”图片以及较暗光照条件下的人脸图像,前 3 种测试图像选取每人 10 张,遮挡面积从 10% 到 50%,遮挡的位置是随机的,最后一个实验选取每人 12 张图像。将所有测试图像大小裁剪为 96×84 。

3.2.1 随机噪声遮挡实验

该实验选取人为添加尺寸大小不同的随机噪声遮挡,实验结果如图 7 所示。




图 7 随机噪声遮挡实验结果

从实验结果可以看出,当遮挡面积在 30% 以内时,本文算法的识别率与 SRC 及 RSC 的相差不大,但当遮挡面积超过 30% 时,本文算法能够继续保持较高的识别率,而 LRC 随着遮挡面积的增大,识别率下降,对结构性噪声也越敏感,当遮挡比例增加到 50% 时,本文算法依旧可以达到 90% 以上的识别率。

3.2.2 块状遮挡实验

这部分实验选取人为添加尺寸大小不同的块状遮挡,实验结果如图 8 所示。




图 8 块状遮挡实验结果

实验结果表明,当人脸图像添加块状遮挡时,本文算法仍然表现出较好的鲁棒性,当遮挡面积为 50% 时,本文算法依旧达到 90% 以上的识别率。在实验过程中,我们发现惩罚因子 μ 对算法起着较为重要的作用。

3.2.3 “狒狒”图片遮挡实验

这部分实验选取人为添加尺寸大小不同的“狒狒”图像遮挡,实验结果如图 9 所示。

(下转第 198 页)

median filtering [J]. The Journal of China Universities of Posts and Telecommunications, 2013, 20(2): 113-119

[9] Muresan D D, Parks T W. Adaptive principal components and image denoising [C] // Proceedings of the 2003 International Conference on Image Processing, 2003: 101-104

[10] Zhang L, Dong W, Zhang D, et al. Two-stage image denoising by principal component analysis with local pixel grouping [J]. Pattern Recognition, 2010, 43(4): 1531-1549

[11] 祁云平, 马慧芳, 佟雨兵, 等. 基于 PSNR 与 SSIM 联合的图像质量评价模型 [J]. 计算机应用, 2007, 27(2): 503-506

(上接第 183 页)

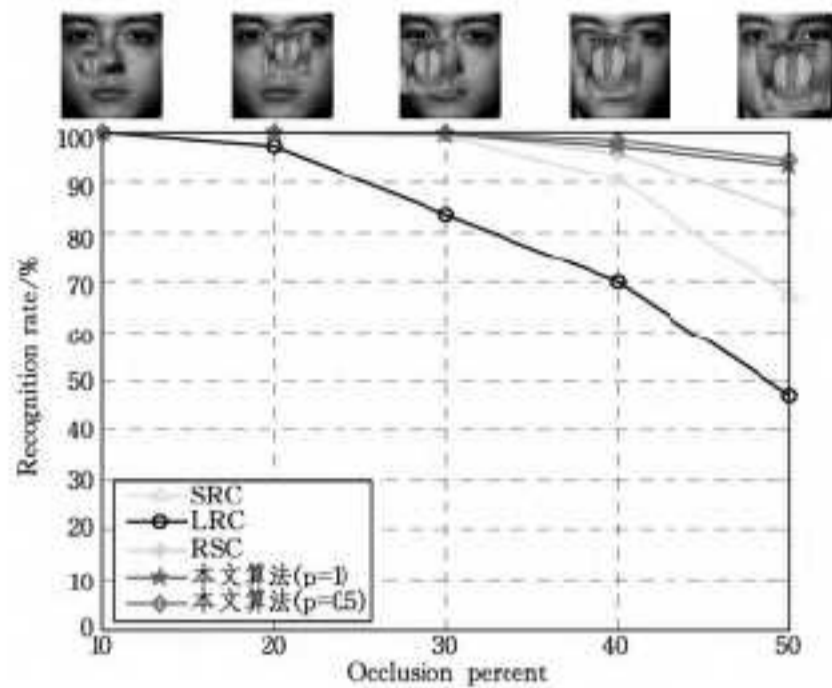


图 9 图片遮挡实验结果

从图 9 中可以看出, 当遮挡面积控制在 40% 之内时, 本文算法与 RSC 取得类似的识别效果; 当遮挡面积为 50% 时, 本文算法的识别率为 93.42%, 比 RSC 约高出 9%。

3.2.4 偏暗图片实验结果

这部分实验选取了 Extended Yale B 中 38 个人、每个人 12 张图像作为测试样本, 人脸图像样本如图 10 所示。这 12 张图像都是在灯光较暗的情况下采集的, 受到比较严重的光照影响, 有的人脸图像眼睛处于阴影处, 有的人脸图像半边脸处于阴影下, 实验结果如表 1 所列。



图 10 不同光照下的人脸样本

表 1 不同光照情况下的人脸识别率

算法	SRC	LRC	RSC	本文算法 ($p=1$)	本文算法 ($p=0.5$)
识别率(%)	82.5	89.3	84.3	92.5	93.7

这组人脸图像由于光照原因导致部分人脸特征信息丢失, 本文算法对这些图像进行实验, 识别效果仍达到 90% 以上, 从而进一步验证了本文算法对光照影响的鲁棒性。

在 AR 库和 Extended Yale B 库上的实验结果表明, 本文算法在以上所有遮挡情况下的识别率都是最优的。当参数 p 选择 0.5 时, 本文识别效果最佳, 由此可见 ℓ_p 范数比 ℓ_1 范数更接近稀疏解, 采用非凸 ℓ_p ($0 \leq p < 1$) 范数最小化能够获得比凸 ℓ_1 范数更好的效果。

结束语 基于矩阵回归理论, 本文提出一种联合低秩和 ℓ_p 稀疏的矩阵回归模型。该模型采用低秩性约束回归误差, 采用 ℓ_p 范数约束回归系数, 使其接近于最稀疏解, 最后用交替方向法计算模型参数。实验证明, 本文算法具有高的识别率, 能够更好地消除遮挡引起的结构性噪声, 且对光照变化也具有更强的鲁棒性。本文算法虽然在处理图像时比传统的回归方法更快, 但是由于需要进行多次迭代优化, 在实际应用中

处理效率仍需要提高。如何提高本文算法的速度是未来需要进一步研究的问题。

参考文献

- [1] 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
- [2] Yang J, Zhang L, Xu Y, et al. Beyond sparsity: The role of L1-optimizer in pattern classification [J]. Pattern Recognition, 2012, 45(3): 1104-1118
- [3] Yang M, Zhang D, Yang J. Robust sparse coding for face recognition [C] // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2011: 625-632
- [4] Candès E J, Li X, Ma Y, et al. Robust principal component analysis? [J]. Journal of the ACM (JACM), 2011, 58(3): 11
- [5] Liu G, Lin Z, Yu Y. Robust subspace segmentation by low-rank representation [C] // Proceedings of the 27th International Conference on Machine Learning (ICML-10). 2010: 663-670
- [6] 杨国亮, 谢乃俊, 罗璐, 等. 基于空间约束低秩图的人脸识别 [J]. 计算机科学, 2014, 41(8): 297-300, 326
- [7] 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
- [8] Huang S M, Yang J F. Kernel linear regression for low resolution face recognition under variable illumination [C] // 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2012: 1945-1948
- [9] Yang J, Qian J, Luo L, et al. Nuclear Norm based Matrix Regression with Applications to Face Recognition with Occlusion and Illumination Changes [J]. arXiv preprint arXiv:1405.1207, 2014
- [10] Lin Zhou-chen, Chen Min-ming, Ma Yi, et al. The augmented Lagrange multiplier method for exact recovery of corrupted low-rank matrices [EB/OL]. 2010-09-26. <http://arxiv.org/pdf/1009.5055>
- [11] Yuan X, Yang J. Sparse and low-rank matrix decomposition via alternating direction methods [OL]. <http://math.nju.edu.cn/~jfyang/files/LRSD-09.pdf>
- [12] Lyu Q, Lin Z, She Y, et al. A comparison of typical ℓ_p minimization algorithms [J]. Neurocomputing, 2013, 119: 413-424
- [13] Zuo W, Meng D, Zhang L, et al. A generalized iterated shrinkage algorithm for non-convex sparse coding [C] // Proceedings of the IEEE international conference on computer vision, 2013: 217-224
- [14] Ganesh A, Lin Z, Wright J, et al. Fast algorithms for recovering a corrupted low-rank matrix [C] // 2009 3rd IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP). IEEE, 2009: 213-216