

引用格式:孙雨浩,陶洋,胡昊. 基于低秩矩阵恢复和 Gabor 特征的遮挡人脸识别[J]. 微电子学与计算机,2020,37(3):42-48.  
[SUN Y H, TAO Y, HU H. Occlusion face recognition based on low-rank matrix recovery and Gabor feature [J]. Microelec-  
tronics & Computer,2020,37(3):42-48. ]

# 基于低秩矩阵恢复和 Gabor 特征的遮挡人脸识别

孙雨浩,陶 洋,胡 昊

(重庆邮电大学 通信与信息工程学院,重庆 400065)

**摘 要:** 针对低秩矩阵恢复算法复杂度过高和训练集样本存在遮挡的问题,本文提出一种基于低秩矩阵恢复和 Gabor 特征的鲁棒表示与分类的遮挡人脸识别方法. 该方法首先通过快速低秩矩阵恢复算法,准确并且快速地求得训练样本图像对应的误差图像;然后,分别对“干净”人脸图像和遮挡误差图像进行 Gabor 变换,得到 Gabor 特征向量;接着,本文提出一种基于 Gabor 特征的遮挡字典压缩算法,可以计算出压缩后的 Gabor 遮挡字典,并用其与训练样本的 Gabor 特征向量构成 Gabor 压缩字典;最后,利用压缩字典对测试样本进行协作表示,获取最终的识别结果. 在 Extended Yale B 和 AR 数据库上的实验结果表明,本方法不仅对遮挡人脸识别具有较强的鲁棒性,而且大大降低了对遮挡人脸图像编码的计算量,缩减了算法的运行时间.

**关键词:** 人脸识别;低秩矩阵恢复;Gabor 特征;字典压缩;协作表示

**中图分类号:** TP391.4

**文献标识码:** A

**文章编号:** 1000—7180(2020)03—0042—07

## Occlusion face recognition based on low-rank matrix recovery and Gabor feature

SUN Yu-hao, TAO Yang, HU Hao

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** To solve the problem of low complexity of low-rank matrix recovery algorithm and occlusion of training set samples, this paper proposes an occlusion face recognition method based on low-rank matrix recovery and Gabor feature robust representation and classification. Firstly, the fast low-rank matrix recovery algorithm is used to accurately and quickly obtain the error image corresponding to the training sample image. Then, Gabor transform is performed on the “clean” face image and the occlusion error image respectively to obtain the Gabor feature vector. Then, In this paper, an occlusion dictionary compression algorithm based on Gabor feature is proposed. The compressed Gabor occlusion dictionary can be calculated and used to form a Gabor compression dictionary with Gabor feature vectors of training samples. Finally, the test samples are cooperatively represented by the compression dictionary. The final recognition result. The experimental results on Extended Yale B and AR database show that the proposed method not only has strong robustness to occlusion face recognition, but also greatly reduces the computational complexity of occlusion face image coding and reduces the running time of the algorithm.

**Key words:** face recognition; low-rank matrix recovery; gabor feature; dictionary compression; collaboration representation

## 1 引言

一般人脸识别都要求训练样本不受噪声污染,即前提条件是这些识别的方法都是基于单一样本的单一个体的图像位于同一低秩子空间<sup>[1]</sup>,但是现实场景中,通常都会受到比如姿势、光照、表情变化以及遮挡的各种影响。

本文针对低秩矩阵恢复算法复杂度过高和训练集样本存在遮挡的问题<sup>[2-5]</sup>,提出了一种基于低秩矩阵恢复和 Gabor 特征的鲁棒表示与分类的遮挡人脸识别方法(Gabor Feature based Robust Representation and Classification and Low-rank Recovery, GFRC-LRR). 该方法在快速低秩矩阵恢复方法的基础上,通过 Gabor 变换和遮挡字典压缩的操作,大大缩减了算法的运行时间,在一定程度上也解决了小样本问题,并有效保证了遮挡人脸识别的有效性。

## 2 相关工作

### 2.1 快速低秩矩阵恢复算法

矩阵分解的方法能够快速求解矩阵的低秩分解问题,可避免核范数最小化求解大规模 SVD 的问题. LRR 矩阵分解模型为:

$$\begin{aligned} \min_{A,E} \|A\|_* + \lambda \|E\|_{2,1} \\ \text{s. t. } X = DA + E \end{aligned} \quad (1)$$

式(1)采用核范数是指向量矩阵  $A$  的奇异值的和,用来约束  $A$  的低秩属性, $l_1$  范数用来约束误差图像向量矩阵  $E$  的稀疏属性,根据文献<sup>[7]</sup>可知  $l_1$  范数并不能很好的对  $E$  的稀疏性进行约束,因此,本文使用  $l_{2,1}$  范数代替  $l_1$  范数, $X$  的  $l_{2,1}$  范数定义如下:

$$\|X\|_{2,1} = \sum_{i=1}^m \sqrt{\sum_{j=1}^n X_{ij}^2} \quad (2)$$

不同于  $l_1$  范数的稀疏要求, $l_{2,1}$  范数还要求行稀疏,可以更好的对误差矩阵  $E$  的稀疏性进行约束. 因此,本文提出一种新的低秩矩阵恢复的方法,用  $l_{2,1}$  范数代替  $l_1$  范数,模型可以表示为:

$$\begin{aligned} \min_{A,E} \|A\|_* + \lambda \|E\|_{2,1} \\ \text{s. t. } X = DA + E \end{aligned} \quad (3)$$

为求解式(3),多次的 SVD 使得该类算法的时间复杂度非常高. 针对这种情况,为了降低算法的复杂度,提出一种对式(3)进行快速求解的快速低秩矩阵恢复方法. 受 SVD 分解及非负矩阵分解的启发,把低秩矩阵  $A$  分解成三个较小矩阵的乘积,令  $A = FGH$ ,  $F \in R^{d \times r}$ ,  $G \in R^{r \times r}$ ,  $H \in R^{r \times n}$ , 其中,  $r \ll$

$\min(d, n)$  为一个给定矩阵的秩的上界,并假设  $F$  和  $H$  都有正交列和正交行,则可以得到  $F^T F = I$  和  $HH^T = I$ , 因此,可以得到,  $\|A\|_* = \|FGH\|_* = \|G\|_*$ . 则矩阵  $A$  的核范数最小化问题可以减小到更小的矩阵  $G$  的核范数最小化问题,则得到的新的带有正交约束的核范数正则模型为:

$$\begin{aligned} \min_{G,F,H,E} \|G\|_* + \lambda \|E\|_{2,1} \\ \text{s. t. } X = DFGH + E, F^T F = I, HH^T = I \end{aligned} \quad (4)$$

式(4)为带有等式约束和正交约束的非光滑非凸优化问题. 使用交替方向法(Alternating Direction Method, ADM)<sup>[8]</sup>求解这个等式约束问题. 可得到恢复的“干净”人脸图像矩阵  $A = XA$ , 误差矩阵  $E$ .

### 2.2 Gabor 小波变换

二维 Gabor 小波变换的核函数定义如下<sup>[9]</sup>:

$$\varphi_{u,v}(z) = \frac{\|k_{u,v}\|}{\sigma^2} e^{-\|k_{u,v}\|^2 \|z\|^2 / 2\sigma^2} (e^{ik_{u,v}z} - e^{-\sigma^2/2}) \quad (5)$$

假设  $I(z)$  为一幅灰度图像,则它在  $u$  方向和  $v$  尺度上的 Gabor 表示为:

$$O_{u,v} = I(z) * \varphi_{u,v}(z) \quad (6)$$

为描述 Gabor 滤波器在不同方向不同尺度的响应,一般方法将核函数尺度取值为  $v = \{0, \dots, 4\}$ , 方向取值为  $u = \{0, \dots, 7\}$ , 可以获得 40 个不同的 Gabor 小波函数,本方法也做同样的参数设置,另取  $\sigma = 1.5\pi$ ,  $k_{\max} = \pi/2$ ,  $f = \sqrt{2}$ .

用  $O$  表示图像  $I$  的所有 Gabor 特征向量,则  $O = \{O_{u,v} : u \in \{0, \dots, 7\}, v \in \{0, \dots, 4\}\}$  即每一幅人脸图像产生 40 个 Gabor 特征分量. 应用卷积定理,可以通过快速傅立叶变换从式(6)中导出每个  $O_{u,v}$ :

$$\mathfrak{F}(O_{u,v}) = \mathfrak{F}(I) \mathfrak{F}(\varphi_{u,v}) \quad (7)$$

由式(7)可以得到:

$$O_{u,v} = \mathfrak{F}^{-1} \{ \mathfrak{F}(I) \mathfrak{F}(\varphi_{u,v}) \} \quad (8)$$

接下来对滤波输出进行下采样以减少 Gabor 特征尺寸以及时间和空间复杂度,则可以获得 Gabor 特征向量  $X$  可以表示为:

$$X = (O_{0,0} O_{1,0} \dots O_{7,4}) \quad (9)$$

因此,  $X$  包含 Gabor 小波表示集的所有元素  $X = \{O_{u,v} : u \in \{0, \dots, 7\}, v \in \{0, \dots, 4\}\}$ , 可以作为重要的识别信息.

Gabor 人脸特征向量是局部特征描述符,不仅可以增强人脸特征,还可以在在一定程度上容忍图像局部变形. 所以本算法使用 Gabor 特征向量来代替人脸表示的整体面部特征,对测试人脸图像  $y$ 、“干净”人脸图像  $A$  和遮挡误差图像  $E$  分别进行上述变

换,分别得到对应的增广 Gabor 特征向量  $G(y)$ 、增广 Gabor 特征字典  $G(A)$  和增广 Gabor 遮挡字典  $G(A_e)$ 。

### 2.3 基于协同表示的分类

假设  $y$  为测试样本人脸图像,有  $K$  个人的训练样本,每个人有  $L$  幅图像,  $x_k (k=1,2,\dots,K; l=1,2,\dots,L;)$  为第  $k$  个人的第  $l$  幅训练样本图像,则  $\mathbf{X}_k = [x_{k1} \ x_{k2} \ \dots x_{kL}]$  为第  $k$  个人的图像矩阵,  $\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2 \ \dots \ \mathbf{X}_K]$  为训练样本字典, SRC 方法用  $l_1$  范数最小化求解稀疏表示系数,但是随着训练样本字典行数或列数的增加,算法的运行速度急速下降,即众多学者关注如何提高  $l_1$  范数的计算速度,却忽略了表示的协作性。协作性即由于不同人的面部图像具有相似性,若第  $i$  个人与第  $j$  个人的图像很相似,那么第  $j$  类的训练样本可以用于表示来自第  $i$  类的测试样本。

为提高算法运行效率, Zhang 等人<sup>[10]</sup> 根据上述思想,提出了 CRC 方法。CRC 在计算协作表示系数时,放松对稀疏性的要求,重点关注表示样本的协作性,用  $l_2$  范数代替  $l_1$  范数,一般模型是:

$$\hat{\alpha} = \operatorname{argmin}\{\|y - X\alpha\|_{l_q} + \lambda \|\alpha\|_{l_p}\} \quad (10)$$

式中,  $\lambda$  是正则化参数;  $p, q$  为 1 或 2;  $p$  和  $q$  的不同取值导致 CRC 模型的不同实例化, CRC 模型具体为:

$$\hat{\alpha} = \operatorname{argmin}\{\|y - X\alpha\|_2 + \lambda \|\alpha\|_2\} \quad (11)$$

利用正则化最小二乘法求解式(11)的解为:

$$P = (X^T X + \lambda I)^{-1} X^T \quad (12)$$

式(12)和测试图像没有直接关系,可以提前进行计算,节省算法运行时间。CRC 运行时,将测试图像投影到  $P$  下,再判别测试图像类别,最小二乘协作表示算法<sup>[10]</sup>的算法流程如下:

步骤 1: 利用式(12)计算  $P$ ;

步骤 2: 计算  $y$  在  $P$  下的投影:

$$\hat{y} = Py = [\hat{y}_1 \ \hat{y}_2 \ \dots \ \hat{y}_K]^T$$

步骤 3: 重构出  $K$  个矢量:

$$y_k = X_k \hat{y}_k (k=1,2,\dots,K)$$

步骤 4: 计算表示误差:

$$r_k = \|y - X_k \hat{y}_k\|_2 / \|\hat{y}_k\|_2$$

步骤 5: 获得  $y$  的类别:

$$k = \operatorname{argmin}\{r_k\}$$

## 3 GFRC-LRR 算法设计

### 3.1 基于 Gabor 特征的鲁棒表示

当人脸图像被遮挡时, SRC 通过引入遮挡字典  $A_e$  对遮挡的人脸分量进行编码,成功地解决了人脸

遮挡问题,测试样本  $y$  表达为:

$$y = y_0 + e_0 = [A, A_e] \begin{bmatrix} \beta \\ \beta_e \end{bmatrix} = B\omega \quad (13)$$

然而, SRC 使用的遮挡字典中的原子数量非常大。为了解决上述问题,与 SRC 类似,利用 Gabor 特征进行人脸表示,引入一个带有 Gabor 特征的遮挡字典对遮挡部分进行编码,将式(13)中的特征字典  $A$  和遮挡字典  $A_e$  转换为 Gabor 特征字典  $G(A)$  和基于 Gabor 特征的遮挡字典  $G(A_e)$ ,即基于 Gabor 特征的鲁棒表示形式为:

$$g(y) = [G(A); G(A_e)] [\beta; \beta_e] = X(B)\omega \quad (14)$$

$G(A_e)$  是一个基于 Gabor 特征的遮挡字典;是输入 Gabor 特征向量  $g(y)/G(A_e)$  的编码向量。式(14)中的表示向量可以通过求解式(15)得到:

$$\min_{\omega} \{\|g(y) - G(B)\omega\|_2^2 + \lambda \|\omega\|_{l_p}\} \quad (15)$$

式中,  $\|\cdot\|_{l_p}$  是  $l_p$  范数,在本文中  $p=1$  或 2。在遮挡情况下,遮挡字典  $G(A_e)$  的选择对算法的性能有很大的影响,如何定义  $G(A_e)$  使该方法有效和高效,是一个关键问题。

### 3.2 Gabor 遮挡字典的计算

通过参考文献[11]分析,  $G(A_e)$  是可压缩的。本文提出了一种利用对该字典系数进行适当正则化的方法求出一个紧凑的遮挡字典。

用  $M = G(A_e) = [M_1, M_2, \dots, M_{n_e}] \in R^{m_p \times n_e}$  表示原始的基于 Gabor 特征的遮挡矩阵,每一  $M_i$  为每个原子  $A_e$  生成的 Gabor 特征向量。要计算压缩后的紧凑遮挡字典表示为  $D = [d_1, d_2, \dots, d_q] \in R^{m_p \times q}$ ,在实验过程中,设置  $q$  的值略小于  $n_e/\rho$ ,其中,每个  $d_j, j=1,2,\dots,q$ ,为单位向量,可以得到  $d_j^T d_j = 1$ ,我们期望,压缩以后的遮挡字典  $D$  可以更好的表示原遮挡字典  $M$ ,并通过  $l_p$  范数正则化对表示系数进行正则化。受 CRC 中  $l_2$  范数正则化成功的启发,也可以使用  $l_2$  范数系数正则化。确定  $D$  的目标函数定义为:

$$E_{D,X} = \operatorname{argmin}_{D,S} \{\|M - DS\|_F^2 + \lambda \|S\|_{l_p}\} \\ \text{s. t. } d_j^T d_j = 1, \forall j \quad (16)$$

式中,  $S$  为  $M$  关于  $D$  的表示系数矩阵,  $\lambda$  是一个正则化参数,用来平衡  $F$ -范数项和  $l_p$  范数项(其中,  $p=1$  为  $\|\cdot\|_1$  或者  $p=2$  为  $\|\cdot\|_2$ )。

首先,通过固定  $D$ ,求解系数矩阵  $S$ 。式(16)中的目标函数可以简化为:

$$E_X = \operatorname{argmin}_S \{\|M - DS\|_F^2 + \lambda \|S\|_{l_p}\} \quad (17)$$

对于  $p = 1$ , 可以通过最小化  $l_1$  范数来实现针对式(17)的最小化. 本文中, 根据文献[12] 闭合最小二乘解的方法, 采用  $p = 2$  可以更加有效的求解.

接下来, 通过固定系数矩阵  $\mathbf{S}$ , 更新遮挡字典  $\mathbf{D}$ . 同样目标函数简化为:

$$E_D = \operatorname{argmin}_{\mathbf{S}} \{ \|\mathbf{M} - \mathbf{D}\mathbf{S}\|_F^2 \} \quad \text{s. t. } d_j^T d_j = 1, \forall j \quad (18)$$

依次进行遮挡基  $d_j$  的更新, 当更新  $d_j$  时, 矩阵  $\mathbf{D}$  的其他列, 均为固定的. 则式(18) 中的  $E_D$  可以被转换为:

$$E_{d_j} = \operatorname{argmin}_{d_j} \|\mathbf{M} - \sum_{l \neq j} d_l s_l - d_j s_j\|_F^2 \quad \text{s. t. } d_j^T d_j = 1 \quad (19)$$

令  $\mathbf{F} = \mathbf{M} - \sum_{l \neq j} d_l s_l$ , 式(19) 可以写成:

$$E_{d_j} = \operatorname{argmin}_{d_j} \|\mathbf{F} - d_j s_j\|_F^2 \quad \text{s. t. } d_j^T d_j = 1 \quad (20)$$

使用拉格朗日乘数求解式(20),  $D_{d_j}$  就等价于:

$$E_{d_j, \delta} = \operatorname{argmin}_{d_j} \operatorname{tr}(-\mathbf{F} s_j^T d_j^T - s_j \mathbf{F}^T + d_j \cdot (s_j s_j^T - \delta) d_j^T + \delta) \quad (21)$$

式(21) 中,  $\delta$  为一个标量变量. 可以看出  $E_{d_j, \delta}$  为零矩阵时得到式(21) 得到最佳解, 由此可以得到:

$$d_j = \mathbf{F} s_j^T (s_j s_j^T - \delta)^{-1} \quad (22)$$

因为  $(s_j s_j^T - \delta)^{-1}$  是一个标量, 在  $d_j^T d_j = 1$  的限制下, 式(22) 的解为:

$$d_j = \mathbf{F} s_j^T / \|\mathbf{F} s_j^T\|_2 \quad (23)$$

由此可以更新所有的向量  $d_j$ , 因此整个字典集  $\mathbf{D}$  也可以被更新.

循环更新式(17) 至式(23), 直到相邻的迭代中  $E_{d_j}$  的值足够接近, 或者达到了最大的迭代次数. 至此, 可以得到压缩后的 Gabor 遮挡字典  $\mathbf{D}$ .

### 3.3 基于 Gabor 特征的鲁棒分类

文献[2] 中 SRC 方案假设人脸图像表示残差是稀疏的, 由于单位矩阵中的原子数量非常大, 因此需要对编码系数施加  $l_1$  范数稀疏性来实现鲁棒且唯一的表示, 但这使得 SRC 的复杂度非常高. 然而, 当采用 Gabor 特征时, 学习到一个紧凑的基于遮挡的字典  $\mathbf{D}$ , 因此可以不再需要使用  $l_1$  范数稀疏性对字典上的编码系数进行正则化.

对于一个给定的人脸 Gabor 特征  $g(y)$ , 通常它的维数要远高于经过 Gabor 遮挡字典计算的原子字典  $B_D = [\mathbf{G}(\mathbf{A})\mathbf{D}]$ , 那就意味着字典  $B_D$  并不是完整的, 因此这个系统

$$g(y) \approx B_D \omega_D \quad (24)$$

通常是一个过确定系统, 这意味着即使没有正

则化, 式(24) 的解也是稳定的. 但是适当的正则化 (如  $l_2$  范数) 可以使表示更加稳定. 此外, 正则化会使表示系数更小, 这将使与错误类关联的系数值更低. 这增加了表示系数的辨识, 有利于最终的人脸识别. 本文利用  $l_1$  范数和  $l_2$  范数对编码系数进行了正则化, 并对结果进行了检验. 基于 Gabor 特征的分类算法流程步骤如下:

步骤 1: 输入 Gabor 特征字典  $\mathbf{G}(\mathbf{A})$ , Gabor 压缩后的遮挡字典  $\mathbf{D}$ ,  $g(y)$

步骤 2: 求解  $l_p$  最小化 ( $p = 1$  或  $2$ ) 问题 (拉格朗日公式):

$$\hat{\omega}_D = \operatorname{argmin}_{\omega_D} \{ \|\mathbf{g}(y) - [\mathbf{G}(\mathbf{A})\mathbf{D}]\omega_D\|_2^2 + \zeta \|\omega_D\|_{l_p} \} \quad \omega_D = [s, s_D]; \hat{\omega}_D = [\hat{s}, \hat{s}_D] \quad (25)$$

$\zeta$  是一个正则化参数.

步骤 3: 计算表示残差:

$$r_i(y) = \|\mathbf{g}(y) - \hat{\mathbf{D}}\hat{s}_D - \mathbf{G}(\mathbf{A}_i)\theta_i(\hat{s})\|_2 \quad i = 1, \dots, K \quad (26)$$

步骤 4: 输出测试样本图像  $y$  的类别:

$$\operatorname{identity}_y = \operatorname{argmin}_i r_i(y) \quad (27)$$

### 3.4 时间复杂度分析

为分析本方法中 Gabor 遮挡字典压缩的表示模型式(14) 中选择  $l_2$  范数而不是  $l_1$  范数对时间复杂度的影响, 在此将利用  $l_1$  范数求解式(14) 的方法称为 GFRC-LRR- $l_1$ .

常用  $l_1$  正则化稀疏编码方法的经验复杂度为  $O(m^2 n^*)$ , 其中  $n^* = 1.5^{[13]}$ , 然而  $l_2$  范数正则化编码的时间复杂度仅为  $O(mn)$ , 因为编码投影矩阵  $\mathbf{P}$  可以离线计算, 其中  $m$  为人脸特征维数,  $n$  为字典原子数. 对于本文提出的 GFRC-LRR 方法, 在傅里叶域中提取 Gabor 特征非常快, 其时间复杂度与  $l_1$  范数正则化稀疏编码相比可以忽略不计.

在有遮挡的人脸识别情况下, 也很容易得到 GFRC-LRR- $l_1$  的时间复杂度为  $O(m^2(n+m/\rho)^\epsilon)$ ,  $\rho \approx 40$ , 这比 SRC 的时间复杂度  $O(m^2(n+m)^\epsilon)$  低很多. 而 GFRC-LRR 的时间复杂度仅为  $O(m^2(n+m/\rho))$ , 是这三种方法中最快的一种.

## 4 实验验证分析

本实验中所有算法均在 CPU 为 Intel Core i5-7200 U @2.50 GHz 2.70 GHz, 内存为 8 GB, 操作系统为 64 位操作系统, Matlab 版本为 Matlab2016a 环境下进行.

本实验采用比较了 GFRC-LRR、SVD<sup>[6]</sup>、

GRRC<sup>[11]</sup>、CESR<sup>[14]</sup>、SSEC<sup>[15]</sup>、和 K-SVD<sup>[16]</sup>等方法在 Extended Yale B 与 AR 两个数据库上进行了实验,以证明本文所提的算法的有效性. 在 Extended Yale B 数据库上执行随机遮挡人脸识别,在 AR 数据库上执行真实伪装人脸识别.

实验中参数设置情况见表 1,如无特殊说明,对比方法参数选用同样的设置.

表 1 GFRC-LRR 方法仿真参数表

| 参数说明           | 数值                 |
|----------------|--------------------|
| Gabor 变换最大频率   | $K_{\max}=\pi/2$   |
| Gabor 变换间距矢量   | $f=\sqrt{2}$       |
| Gabor 小波滤波器的宽度 | $\sigma=1.5\pi$    |
| Gabor 变换方向     | $u=\{0,\cdots,7\}$ |
| Gabor 变换尺度     | $v=\{0,\cdots,4\}$ |
| 下采样参数          | $\rho=40$          |
| 字典压缩模型正则化参数    | $\lambda=0.005$    |
| 压缩 Gabor 遮挡字典列 | $q$ 略小于 $n_e/\rho$ |

4.1 随机块遮挡人脸识别

本节在 Extended Yale B 数据库上验证各方法在光照变化的情况下在不同程度的遮挡下的识别能力. 测试集选取了子集 I、子集 II 和子集 III 的所有 1 170 张图像,训练集 1 选取子集 III 上每张图像中分别添加 0~70% 的随机遮挡共  $453\times8=3\ 624$  张图像,训练集 2 选取子集 IV 中每张图像分别添加 0~70% 的随机遮挡的  $524\times8=4\ 192$  张图像,所有图像裁剪为  $96\times84$  像素.

模拟了不同级别的连续遮挡,从 0 到 70%,将每个测试图像中的随机位置的方块替换为一个不相关的图像,其大小由遮挡率决定. 每个测试图像的遮挡位置是随机选择的,计算机不知道. 图 1 通过一个例子说明了分类过程.




图 1 带有遮挡的人脸识别示例

图 2 和图 3 分别给出了在不同比例块遮挡情况下,各方法的识别率随着遮挡比例的变化情况.

通过图 2 和图 3 可看出,在无遮挡或遮挡面积较小时,GFRC-LRR 方法和 SVD、K-SVD 方法一样都具有很高的识别率. 当遮挡面积较大时,在训练集




图 2 训练集 1 上各方法识别率随遮挡比例变化




图 3 训练集 2 上各方法识别率随遮挡比例变化

1 光照条件较好时 GFRC-LRR 方法和其他方法一样,虽然随着遮挡面积的增大各方法识别性能有所下降,但整体识别性能较好;在训练集 2 光照条件更差时,各方法的识别率随着遮挡面积的增大都下降明显,其中,GFRC-LRR 和 SVD、GRRC 方法的识别性能略有优势.

接下来验证遮挡情况下各方法的时间性能,选取训练集 1 中 30% 遮挡的样本做训练样本,其余设置和上文相同. 各方法识别率和运行速度列于表 2 中. 由表 2 可以看出,在 Extended Yale B 数据库上,GDR-CRC- $L_1$  的识别率最高可以达到 98. 11%,比 GFRC-LRR 高 0. 19%,但 GFRC-LRR 的速度比 GFRC-LRR- $L_1$  快 1350 倍;GFRC-LRR、SRC( $l_1-l_s$ ) 和 SRC(ALM)达到次佳识别率 97. 92%,但 GFRC-LRR 的速度比 SRC( $l_1-l_s$ ) 和 SRC(ALM)快 1595 和 37. 4 倍.

4.2 真实伪装的人脸识别

本节在 AR 数据库上进行真实伪装的人脸遮挡识别实验. 随机选取 65 个男性和 54 个女性的人脸图像为实验数据. 选每人 8 张无遮挡图像构成测试样本,如图 4(a)所示;选取每人 3 张有围巾遮挡的图像构成训练集 1,如图 4(b)所示;选取每人 3 张有太阳镜遮挡的图像构成训练集 2,如图 4(c)所示.

| 表 2 Extended Yale B 数据库上识别率和运行时间 |         |         |
|----------------------------------|---------|---------|
| 算法                               | 识别率/%   | 运行时间/s  |
| $\text{SRC}(l_1-l_s)$            | 97.92   | 5.423 8 |
| $\text{SRC}(\text{ALM})$         | 97.92   | 0.127 0 |
| $\text{GFRC-LRR-L}_1$            | 98.11   | 4.589 1 |
| $\text{GFRC-LRR}$                | 97.92   | 0.003 4 |
| Speed-up                         | 37—1595 |         |




图 4 AR 数据库上部分样本图像

所有图像裁剪为  $112 \times 92$  像素. 对所有图像进行 4 倍、3 倍、2 倍和 1 倍下采样, 像素维数分别对应于  $14 \times 11 = 154$ ,  $28 \times 32 = 644$ ,  $56 \times 46 = 2\,576$  和  $112 \times 92 = 10\,304$ . 表 3~4 给出了各种方法在训练集不同的情况下的识别率.

| 表 3 各方法在 AR 数据库训练集 1 上的识别率 % |       |       |       |        |
|------------------------------|-------|-------|-------|--------|
| 像素维数                         | 训练集 1 |       |       |        |
|                              | 154   | 644   | 2 576 | 10 304 |
| SVD                          | 2.52  | 13.73 | 72.55 | 91.32  |
| K-SVD                        | 2.52  | 13.73 | 70.31 | 91.32  |
| CSEr                         | 28.85 | 39.69 | 38.66 | 38.38  |
| SSEC                         | 27.73 | 50.14 | 49.58 | 48.46  |
| GRRC                         | 18.78 | 36.91 | 71.42 | 91.76  |
| GFRC-LRR                     | 20.89 | 37.78 | 73.31 | 91.89  |

| 表 4 各方法在 AR 数据库训练集 2 上的识别率 % |       |       |       |        |
|------------------------------|-------|-------|-------|--------|
| 像素维数                         | 训练集 2 |       |       |        |
|                              | 154   | 644   | 2 576 | 10 304 |
| SVD                          | 3.92  | 17.89 | 45.66 | 43.98  |
| K-SVD                        | 3.36  | 16.34 | 43.14 | 42.58  |
| CSEr                         | 2.52  | 6.89  | 2.80  | 2.80   |
| SSEC                         | 51.83 | 64.43 | 48.74 | 39.78  |
| GRRC                         | 23.03 | 44.85 | 76.12 | 87.43  |
| GFRC-LRR                     | 24.45 | 44.78 | 76.09 | 87.51  |

从表 3 和表 4 中可以看出, 在像素维数较低时, GFRC-LRR 方法的识别率低于 CESR 和 SSEC 方法, 虽然如此, CESR 方法在测试集 2 上识别率极低, 可能是因为无法区分黑色围巾遮挡和黑色胡子.

在像素维数较高时, GFRC-LRR 方法和 GRRC 方法一样识别性能表现优异, 但 GFRC-LRR 方法的时间性能优于 GRRC.

接下来验证遮挡情况下各方法在 AR 数据库上的时间性能, 进行遮挡实验时在像素维数较高的情况下的实验, 选取训练集 1 戴围巾遮挡的图像为训练集, 像素维数为 10 304, 其余设置和上文相同. 各方法识别率和运行速度列于表 5 中.

| 表 5 AR 数据库上各方法识别率和运行时间   |        |         |
|--------------------------|--------|---------|
| 算法                       | 识别率/%  | 运行时间/s  |
| $\text{SRC}(l_1-l_s)$    | 90.86  | 1.787 8 |
| $\text{SRC}(\text{ALM})$ | 90.28  | 0.057 8 |
| $\text{GFRC-LRR-L}_1$    | 91.89  | 1.130 9 |
| $\text{GFRC-LRR}$        | 90.86  | 0.002 6 |
| Speed-up                 | 22—687 |         |

由表 5 可以看出, 在 AR 数据库上, GFRC-LRR- $L_1$  的识别率最高可以达到 91.89%, 比 GFRC-LRR 高 1.03%, 但 GFRC-LRR 的速度比 GFRC-LRR- $L_1$  快 435 倍; GFRC-LRR 和  $\text{SRC}(l_1-l_s)$  达到次佳识别率 90.86%, 但 GFRC-LRR 的速度比  $\text{SRC}(l_1-l_s)$  和  $\text{SRC}(\text{ALM})$  快 1595 和 37.4 倍. 根据上述实验结果, 可以看出, GFRC-LRR 的运行速度比其他方法具有明显优势, 这意味着 GFRC-LRR 在实际的大规模人脸识别应用中更有利.

## 5 结束语

本文提出了基于低秩矩阵恢复和 Gabor 特征的鲁棒表示和分类的遮挡人脸识别方法, 主要运用了快速低秩矩阵恢复算法和提出一种 Gabor 遮挡字典计算的算法. 本方法不仅提高了遮挡人脸图像的识别率, 而且可以计算出紧凑的遮挡字典, 它比原 SRC 方案的原子要少得多. 另外, 本文所学习的 Gabor 遮挡字典的编码系数运用了  $l_2$  范数来正则化, 这大大降低了编码的计算成本. 我们在不同的条件下评估了该方法, 实验结果表明, 提出的 GFRC-LRR 算法具有更好的识别性能, 提高了识别率, 同时大大降低了计算量. 这使得它在现实世界应用中的遮挡人脸识别更实用.

## 参考文献:

[1] 胡正平, 李静. 基于低秩子空间恢复的联合稀疏表示人脸识别算法[J]. 电子学报, 2013, 41(5): 987-991.

[2] WRIGHT J, YANG A Y, SASTRY S S, et al. Robust face recognition via sparse representation[J].

- IEEE Transactions on Pattern Analysis & Machine Intelligence, 2009, 31(2):210-227.
- [3] DENG W, HU J, GUO J. Extended SRC: under sampled face recognition via intraclass variant dictionary [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(9):1864.
- [4] CANDÈS E J, LI X D, MA Y, et al. Robust principal component analysis[J]. Journal of the American Statistical Association, 2009, 8(1):1-73.
- [5] LIU G, LIN Z, YAN S, 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.
- [6] WANG J W, LE N T, LEE J S, et al. Color face image enhancement using adaptive singular value decomposition in fourier domain for face recognition[J]. Pattern Recognition, 2016, 57(C):31-49.
- [7] COX T L, BOWN J, BELL T R. In advanced l2 reading proficiency assessments, should the question language be in the l1 or the l2?: does it make a difference? [M]. Switzerland: Springer Nature, 2019: 117-136.
- [8] CHENG D, YANG J, WANG J, et al. Double-noise-dual-problem approach to the augmented Lagrange multiplier method for robust principal component analysis[J]. Soft Computing, 2015(21):1-10.
- [9] 黄森, 王刘涛, 张海朝. 基于 Gabor 小波变换与 K-L 高斯黎曼流形判别的人脸识别[J]. 计算机工程, 2016, 42(9):208-213.
- [10] LEI Z, MENG Y, FENG X. Sparse representation or collaborative representation: Which helps face recognition? [C]//International Conference on Computer Vision. Barcelona, Spain, 2011:471-478
- [11] YANG M, ZHANG L, SHIU S C K, et al. Gabor feature based robust representation and classification for face recognition with Gabor occlusion dictionary [J]. Pattern Recognition, 2013, 46(7):1865-1878.
- [12] 林国军, 解梅. 一种鲁棒协作表示的人脸识别算法[J]. 计算机应用研究, 2014, 31(8): 2520-2522.
- [13] KIM S J, KOH K, LUSTIG M, et al. A method for large-scale l1-regularized least squares[J]. IEEE Journal on Selected Topics in Signal Processing, 2007, 1(4):606-617.
- [14] HE R, ZHENG W S, HUB G. Maximum correntropy criterion for robust face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1561-1676
- [15] LI X X, DAI D Q, ZHANG X F, et al. Structured sparse error coding for face recognition with occlusion [J]. IEEE Transactions on Image Processing, 2013, 22(5):1889-1900.
- [16] AHARON M, ELAD M, BRUCKSTEIN A M. The K-SVD: an algorithm for designing of overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.

## 作者简介:

**孙雨浩** 男, (1994-), 硕士研究生. 研究方向为人脸识别、图像处理、模式识别. E-mail: sunyh1108@qq.com.

**陶 洋** 男, (1964-), 博士后, 教授, 硕士生导师. 研究方向为无线传感器网络、异构网络、模式识别等.

**胡 昊** 男, (1994-), 硕士研究生. 研究方向为图像处理、模式识别.