

DOI: 10.11992/tis.201711026

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.tp.20180428.1122.002.html>

结构化加权稀疏低秩恢复算法在人脸识别中的应用

吴小艺, 吴小俊

(江南大学物联网工程学院, 江苏 无锡 214122)

摘要: 针对训练样本或测试样本存在污损的情况, 提出一种结构化加权稀疏低秩恢复算法 (structured and weighted-sparse low rank representation, SWLRR)。SWLRR 对低秩表示进行加权稀疏约束和结构化约束, 使得低秩表示系数更加趋近于块对角结构, 进而可获得具有判别性的低秩表示。SWLRR 将训练样本恢复成干净训练样本后, 再根据原始训练样本和恢复后的训练样本学习到低秩投影矩阵, 把测试样本投影到相应的低秩子空间, 即可有效地去除测试样本中的污损部分。在几个人脸数据库上的实验结果验证了 SWLRR 在不同情况下的有效性和鲁棒性。

关键词: 人脸识别; 结构化; 加权稀疏; 低秩表示; 子空间投影

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2019)03-0455-09

中文引用格式: 吴小艺, 吴小俊. 结构化加权稀疏低秩恢复算法在人脸识别中的应用 [J]. 智能系统学报, 2019, 14(3): 455-463.

英文引用格式: WU Xiaoyi, WU Xiaojun. A low rank recovery algorithm for face recognition with structured and weighted sparse constraint[J]. CAAI transactions on intelligent systems, 2019, 14(3): 455-463.

A low rank recovery algorithm for face recognition with structured and weighted sparse constraint

WU Xiaoyi, WU Xiaojun

(School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Herein, a structured and weighted sparse low-rank recovery algorithm (SWLRR) is proposed to deal with trained or tested samples that are corrupt. The SWLRR constrains the low-rank representation by incorporating the structured and weighted sparse constraints, enabling the low-rank representation coefficient matrix to be closer to the block diagonal. Then, a discriminative structured representation can be obtained. After recovering the clean training samples from the corrupted training samples using SWLRR, the low-rank projection matrix is learnt by the low-rank projection matrix according to the original and recovered training samples, whereas the test samples are projected into the corresponding low-rank subspaces. In this way, the corrupted regions can be removed efficiently from the test samples. The experimental results on several face databases validate the effectiveness and robustness of the SWLRR under different situations.

Keywords: face recognition; structured; weighted sparse; low-rank representation; subspace projection

作为计算机视觉和模式识别中最具挑战性的研究课题之一, 人脸识别 (FR)^[1-8] 在近几年一直是研究的热点课题。在实际生活中, 人脸识别也被广泛应用, 比如视频监控、安全相关访问和人机

交互技术等。随着研究的深入, 目前无污损情况下的人脸识别已经达到理想的效果。但在面部有遮挡和伪装的情况下进行人脸识别和分类仍然是一个具有挑战性的难题。

1 低秩稀疏表示理论

近年来, 基于稀疏表示的方法在人脸识别领域内被广泛使用。Wright 等^[5] 提出基于稀疏表示

收稿日期: 2017-11-21. 网络出版日期: 2018-05-02.

基金项目: 国家自然科学基金项目 (61672265, 61373055); 江苏省教育厅科技成果产业化推进项目 (JH10-28); 江苏省产学研创新项目 (BY2012059).

通信作者: 吴小俊. E-mail: xiaojun_wu_jnu@163.com.

分类 (SRC)。稀疏表示分类的主要思想是将一个测试样本看成一个过完备字典中少量原子的线性表示,并计算出测试样本关于字典矩阵的编码系数,最后利用最小重构误差法分类。近年来,很多基于 SRC 的算法被相继提出。Zhang 等^[9]提出了基于协同表示的分类 (CRC),将 SRC 中的 l_1 -norm 换为 l_2 -norm,在保证分类结果理想的同时加快了分类速度。针对小样本问题,Deng 等^[10]提出 ESRC,使用辅助的类内变化字典表示训练样本和测试样本之间可能存在的变化。RRC^[8](regularized robust coding) 算法和 JRPL^[11](joint representation and pattern learning) 算法进一步增强了 SRC 算法在存在污染情况下的鲁棒性。虽然 SRC 及其改进算法达到了较高的识别率,但是当测试样本和训练样本中都存在遮挡或像素污损的时候,算法的分类效果依然会受到影响。而直接忽略被遮挡的训练样本,隐藏在原始训练样本中的判别信息就不能被充分地利用,从而导致性能变差。因此, SRC 在实际的应用中受到了限制。

最近的研究表明,视觉数据具有低秩结构,低秩矩阵恢复技术成为研究的热点题。Candès 等^[12]提出的鲁棒主成分分析 (robust principal component analysis, RPCA) 可以从被污染的数据中恢复出原始数据的低秩矩阵,随后 Liu 等^[13]提出了低秩表示 (low-rank representation, LRR) 方法。基于 RPCA 和 LRR,研究者提出了很多方法来处理训练样本中存在的遮挡和污损。Chen 等^[7]使用 RPCA 把原始的训练数据分解为低秩矩阵和误差矩阵,同时让不同类的低秩部分结构不相关,在一定程度上增加了鉴别信息。Ma 等^[14]提出的 DLRD_SR (discriminative low-rank dictionary for sparse representation) 在字典学习的过程中加入了低秩和稀疏约束,在样本存在污染时取得了较好的分类效果。Zhang 等^[15]提出 LSLR (learning structured low-rank representations),通过在训练过程中加入结构化约束,构造出了一个结构化的字典,使得系数更加趋近于块对角结构,并通过优化后的系数对测试样本进行分类,但是 LSLR 并没有着重加强每类子字典对同类训练样本的表示能力。Nguyen^[16]在 LRR 的基础上增加了标签约束项和重构误差约束项,让类内的重构误差减小而类间的重构误差增大,进一步加强了每一类子字典的判别性。Chang^[17]在算法中加入权重约束项,使得在块对角上的低秩系数值更大,非块对角上的值更加趋于 0,同时提高了表示系数和字典的判别性。Zhang 等^[18]提出 BDLRR (block-diagonal

low-rank representation),将对表示系数的块对角约束和权重约束相结合,得到了更加理想的表示系数。而上述这些基于低秩矩阵恢复的方法的主要思想都是构造一个干净的具有判别性的字典,消除训练样本中的遮挡带来的影响,但是并没有考虑到测试样本中存在遮挡的情况。如果测试样本中也存在遮挡且没有通过算法被有效地移除,也将导致测试样本无法正确分类,会对实验结果产生很大的影响。

针对样本中存在污染的问题,本文提出一种结构化加权稀疏低秩恢复算法。该算法在原始低秩表示的基础上对低秩系数进行了加权和结构化稀疏约束,可以得到一个结构化的判别低秩系数,而且同类样本的表示系数会有更强的相关性。跟上述方法不同的是,受到 Chen 等^[19]提出的 DLRR (discriminative low-rank representation) 的启发,本文在得到训练样本的恢复样本后,根据原始训练样本和恢复后的干净训练样本学习到一个低秩投影矩阵,并对存在遮挡的测试样本进行投影,有效地消除了测试样本中存在的遮挡,解决了测试样本中存在遮挡从而影响最终分类结果的问题。最后使用 SRC 方法对恢复后的测试样本进行分类识别。在几个标准数据上的实验结果验证了所提出方法的有效性和鲁棒性。

2 相关工作

2.1 稀疏表示分类

稀疏表示分类方法的主要思想是将测试样本表示为训练样本的稀疏线性组合,并计算测试样本和每个类别的重构误差,最后将测试样本分在最小重构误差对应的类别中。假设 $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \cdots \ \mathbf{x}_T] \in \mathbf{R}^{m \times T}$ 表示 C 类训练样本,样本总数为 T , \mathbf{X} 的每一列为一个训练样本图像,在本文中也记为 $\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2 \ \cdots \ \mathbf{X}_C]$,其中 \mathbf{X}_i 表示第 i 类训练样本,测试样本 $\mathbf{y} \in \mathbf{R}^m$ 。SRC 的目标函数为

$$\min_{\alpha} \|\mathbf{y} - \mathbf{X}\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (1)$$

式中: $\lambda > 0$ 为正则化参数,用来平衡误差项和稀疏项。在得到系数 α 后,测试样本 \mathbf{y} 可以通过最小残差法分类,即

$$\text{identity}(\mathbf{y}) = \arg \min_i \|\mathbf{y} - \mathbf{X}_i \alpha_i\|_2^2 \quad (2)$$

式中 α_i 是第 i 类训练样本对应的系数。

2.2 低秩矩阵恢复

要从有遮挡的训练样本中恢复出干净的训练样本,需要借助于低秩矩阵恢复技术。有遮挡的训练样本可以表示为低秩矩阵 \mathbf{D} 和对应的稀疏误差 \mathbf{E} 之和,即 $\mathbf{X} = \mathbf{D} + \mathbf{E}$ 。

因此, Candès 等^[14] 提出使用鲁棒 PCA 方法对 X 进行恢复, 目标函数为

$$\min_{D,E} \text{rank}(D) + \lambda \|E\|_0, \quad \text{s.t. } X = D + E \quad (3)$$

由于式 (3) 是非凸的, 常用的做法是把 l_0 范数换成 l_1 范数, 把秩函数换成核范数 $\|D\|_*$ (矩阵 D 的奇异值之和), 因此式 (3) 变为

$$\min_{D,E} \|D\|_* + \lambda \|E\|_1, \quad \text{s.t. } X = D + E \quad (4)$$

RPCA 假设数据来自一个单独的子空间, 但是实际中的数据通常来自多个子空间^[20], 基于此, Liu 等^[15] 推广了 RPCA 的概念并提出了更一般的秩最小化问题, 即低秩表示, 目标函数为

$$\min_{Z,E} \|Z\|_* + \lambda \|E\|_1, \quad \text{s.t. } X = AZ + E \quad (5)$$

式中: A 为字典矩阵; Z 为表示系数。上述凸优化问题可以使用不精确的增广拉格朗日乘子 (ALM) 算法在多项式时间内有效地解决。在得到算法的最优解 (Z^*, E^*) 后, AZ^* (或 $X - E^*$) 就是原始数据 X 的低秩恢复数据。

3 学习结构化的加权稀疏低秩表示

通过结构化加权稀疏低秩表示 SWLRR (structured and weighted low-rank representation) 将污染的样本恢复成干净的样本, 同时学习一个原始训练样本到恢复训练样本的投影矩阵。SWLRR 利用了原始训练样本的标签信息, 并对低秩表示系数进行加权稀疏约束, 使得相似的样本尽可能有相似的表示, 也增强了恢复矩阵的判别能力。

3.1 结构化的加权稀疏低秩表示 (SWLRR)

为了提高 SRC 的性能, 可以利用低秩矩阵恢复技术来解决上面提到的几个影响分类效果的问题。把原始的训练样本分解为干净的训练样本和对应的稀疏误差。受 Zhang 等^[15] 和 Zhang 等^[18] 的启发, 本文在原始式 (5) 的基础上增加了两个对低秩表示系数的约束项, 提出了用 SWLRR 来恢复污染的样本, 同时增强恢复矩阵的判别性。

将 C 类训练样本记为 $X = [X_1 X_2 \cdots X_C] = [x_1 x_2 \cdots x_T] \in \mathbb{R}^{m \times T}$, m 为样本维度, T 为训练样本个数。其中 X_i 表示第 i 类的训练样本, x_i 表示第 i 个训练样本。每个训练样本可由基 $A = [A_1 A_2 \cdots A_N] = [a_1 a_2 \cdots a_K] \in \mathbb{R}^{m \times K}$ 线性表示, K 为基 A 的原子个数, 其中 A_i 表示第 i 类的基, a_i 表示第 i 个基。通过 SWLRR 可学习一个结构化的鉴别低秩字典 $B = [B_1 B_2 \cdots B_C]$, 其中 B_i 为第 i 类的子字典, $B_i = A_i Z_i$, Z_i 为第 i 类的低秩系数。SWLRR 目标函数为

$$\min_{Z,E} \|Z\|_* + \alpha \|D \odot Z\|_0 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 \quad (6)$$

$$\text{s.t. } X = AZ + E$$

式中: α, β, λ 是标量参数; \odot 表示 Hadamard 积 (逐元素相乘); $\|D \odot Z\|_0$ 利用了加权的方法来提升对类内样本表示的相关性; D 是一个和矩阵 Z 大小相同的矩阵, D 的元素 d_{ij} 表示第 i 个基 a_i 到第 j 个训练样本 x_j 的距离 (有很多度量样本之间距离的方法, 本文用欧氏距离的平方来定义两个样本之间的距离, 即 $\|a_i - x_j\|_2^2$)。 $\|D \odot Z\|_0$ 的目的就是通过低秩系数矩阵进行加权约束, 来提高类内表示的相关性, 让相似的样本有更加相似的表示, 加强训练样本的自表示能力, 也在一定程度上提高了表示系数的鉴别性。因为 l_0 范数最小化问题是 NP 难问题, 所以我们将第 2 项写成它的替代形式 $\|D \odot Z\|_1$ 。因此, 式 (6) 可以改写为

$$\min_{Z,E} \|Z\|_* + \alpha \|D \odot Z\|_1 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 \quad (7)$$

$$\text{s.t. } X = AZ + E$$

$\|Z - Q\|_F^2$ 为结构化约束项, 由于当训练样本去除噪声、遮挡、表情和光照影响后, 每一类的样本有着相似的基结构^[14]。根据 2.2 节的讨论, 给定一组基 A , 低秩矩阵恢复可以将污染的矩阵 X 分解成低秩部分 AZ 和稀疏噪声部分 E , 即 $X = AZ + E$ 。根据文献 [15], 基 A 关于训练样本 X 的低秩表示矩阵 Z 应该具有块对角结构:

$$Z^* = \begin{pmatrix} Z_1^* & & & \\ & Z_2^* & & \\ & & \ddots & \\ & & & Z_C^* \end{pmatrix}$$

其中 $Z_1^*, Z_2^*, \dots, Z_C^*$ 为 X_i 相对于 A_i 的表示系数。 $Q = [q_1 q_2 \cdots q_T] \in \mathbb{R}^{K \times T}$ 是一个理想的块对角矩阵, 其中 $q_i = [0 \cdots 111 \cdots]^T \in \mathbb{R}^K$ 为样本 x_i 的对应向量, 向量中的非 0 元素由 x_i 所属的类来决定, 如果 x_i 属于第 L 类, q_i 中只有对应于子字典 A_L 的项为 1, 其余全部为 0。

3.2 算法优化求解

基于 LRR 中原始训练数据 X 可以代替 A 作为表示基, 式 (7) 可变更为

$$\min_{Z,E} \|Z\|_* + \alpha \|D \odot Z\|_1 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 \quad (8)$$

$$\text{s.t. } X = XZ + E$$

为了将变量分离, 引入辅助变量 P, J , 则式 (8) 变成:

$$\min_{Z,P,J,E} \|P\|_* + \alpha \|D \odot J\|_1 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 \quad (9)$$

$$\text{s.t. } X = XZ + E, Z = P, Z = J$$

式 (9) 可以用 ALM 求解, 它对应的增广拉格朗日函数为

$$L(Z, P, J, E, Y_1, Y_2, Y_3, \mu) = \|P\|_* + \alpha \|D \odot J\|_1 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 + \langle Y_1, X - XZ - E \rangle + \langle Y_2, Z - P \rangle + \langle Y_3, Z - J \rangle + \frac{\mu}{2} (\|X - XZ - E\|_F^2 + \|Z - P\|_F^2 + \|Z - J\|_F^2) \quad (10)$$

式中: Y_1, Y_2, Y_3 为拉格朗日乘子; $\mu > 0$ 为惩罚参数; $\langle Y_2, Z - P \rangle = \text{tr}(Y_2^T (Z - P))$, 本文利用含有自适应惩罚项的线性交替方向法 (linearized alternating direction method with adaptive penalty, LADM AP)^[21-22] 来优化式 (10), 为描述方便, 式 (10) 可以进一步简化为

$$L(Z, P, J, E, Y_1, Y_2, Y_3, \mu) = \|P\|_* + \alpha \|D \odot J\|_1 + \beta \|Z - Q\|_F^2 + \lambda \|E\|_1 + q(Z, P, J, E, Y_1, Y_2, Y_3, \mu) - \frac{1}{2\mu} (\|Y_1\|_F^2 + \|Y_2\|_F^2 + \|Y_3\|_F^2) \quad (11)$$

式中 $q(Z, P, J, E, Y_1, Y_2, Y_3, \mu) = \frac{\mu}{2} \left(\left\| X - XZ - E + \frac{Y_1}{\mu} \right\|_F^2 + \left\| Z - P + \frac{Y_2}{\mu} \right\|_F^2 + \left\| Z - J + \frac{Y_3}{\mu} \right\|_F^2 \right)$ 。

可以交替优化变量 Z, P, J, E , 即优化其中一个时, 固定另外 3 个变量。每次迭代时变量的更新情况如下。

1) 固定 Z, J, E , 更新 P

式 (11) 可转化为

$$P_{k+1} = \arg \min_P \varepsilon \|P\|_* + \frac{1}{2} \|P - A\|_F^2 \quad (12)$$

式中: $\varepsilon = \frac{1}{\mu}$, $A = Z + \frac{Y_2}{\mu}$ 。式 (12) 的解可以通过式 (13) 求, 即

$$P = USV^T = UT_\varepsilon[S]V^T \quad (13)$$

式中: USV^T 是 A_k 的奇异值分解; $T_\varepsilon[S]$ 是软阈值算子^[23], 它对向量或矩阵逐元素进行操作, 其定义为

$$T_\varepsilon[S] = \begin{cases} S_{i,j} - \varepsilon, & S_{i,j} > \varepsilon \\ S_{i,j} + \varepsilon, & S_{i,j} < -\varepsilon \\ 0, & \text{其他} \end{cases} \quad (14)$$

2) 固定 J, E, P , 更新 Z

将 J, E, P 这 3 个变量看成常数后, 式 (11) 可以写成式 (15) 只关于变量 Z 的函数:

$$L(Z) = \min_Z \beta \|Z - Q\|_F^2 + \frac{\mu}{2} \left(\left\| X - XZ - E + \frac{Y_1}{\mu} \right\|_F^2 + \left\| Z - P + \frac{Y_2}{\mu} \right\|_F^2 + \left\| Z - J + \frac{Y_3}{\mu} \right\|_F^2 \right) \quad (15)$$

为了求出使式 (15) 最小的 Z 值, 将对 Z 求导, 使 $\frac{\partial L(Z)}{\partial Z} = 0$, 即可得到本次迭代 Z 的最优值:

$$Z = (2\beta + \mu X^T X + 2\mu)^{-1} (2\beta Q + \mu X^T X - \mu X^T E + X^T Y_1 + \mu P + \mu J - Y_2 - Y_3) \quad (16)$$

3) 固定 Z, E, P , 更新 J

$$J_{k+1} = T(Z_{k+1} + \frac{Y_{3,k}}{\mu_k}) \quad (17)$$

4) 固定 Z, P, J , 更新 E

$$E_{k+1} = T(X - XZ_{k+1} + \frac{Y_{1,k}}{\mu_k}) \quad (18)$$

式 (16)、(17) 中的 T 为软阈值算子, 算法 1 总结了式 (10) 的优化过程。通过算法 1 迭代更新得到问题, 即式 (7) 的最优解 (Z^*, E^*) 那么被恢复的图像和对应的误差则为 AZ^* 和 E^* 。图 1 展示了不同类的训练样本和对应的恢复结果。



(a) 原始训练样本



(b) 恢复后的训练样本

图 1 SWLRR 算法得到的恢复结果

Fig. 1 Recovery results obtained using SWLRR method

算法 1 用 LADMAP 求解问题 (即式 (8))

输入 训练数据样本 $X = [X_1 X_2 \cdots X_C] \in \mathbf{R}^{m \times n}$,

参数 $\lambda > 0, \beta > 0$;

输出 (Z^*, E^*) 。

初始化 $Z_0 = P_0 = J_0 = E_0 = Y_{1,0} = Y_{2,0} = Y_{3,0} = 0$,

$\mu_{\max} = 10^8, \rho_0 = 1.1, \delta = 10^{-6}, \text{maxiter} = 1\ 000, k = 0$ 。

若不满足式 (7) 中的收敛条件, 则循环下列更新步骤:

1) 根据式 (13) 更新 P ;

2) 根据式 (16) 更新 Z ;

3) 根据式 (17) 更新 J ;

4) 根据式 (18) 更新 E ;

5) 更新拉格朗日乘子:

$$Y_{1,k+1} = Y_{1,k} + \mu_k (X - XZ_{k+1} - E_{k+1});$$

$$Y_{2,k+1} = Y_{2,k} + \mu_k (Z_{k+1} - P_{k+1});$$

$$Y_{3,k+1} = Y_{3,k} + \mu_k (Z_{k+1} - J_{k+1});$$

6) 更新参数 μ : $\mu_{k+1} = \min(\rho\mu_k, \mu_{\max})$;

7) 检查收敛条件:

$$\max(\|X - XZ_{k+1} - E_{k+1}\|_\infty, \|Z_{k+1} - P_{k+1}\|_\infty, \|Z_{k+1} - J_{k+1}\|_\infty) < \delta$$

8) 更新 $k \leftarrow k + 1$;

3.3 低秩投影矩阵

在对样本进行分类时, 训练样本和测试样本中存在的遮挡都会对分类结果产生影响。所以将训练样本恢复成干净样本后, 接下来要考虑的问题就是如何移除测试样本中可能存在的遮挡。受 Bao 等^[24] 启发, 可以通过学习一个低秩投影矩阵, 将受污染的测试样本投影到相应的低秩子空间。

根据算法 1 求出低秩表示系数 Z^* 后, $Y = XZ^* \in \mathbf{R}^{m \times T}$ 即为训练样本的低秩恢复。通过原始训练样本 X 和其低秩恢复 Y , 可以学习一个低秩投影矩阵 A 。可通过优化如下问题得到低秩投影矩阵 A :

$$\min_A \|A\|_*, \text{ s.t. } Y = AX \quad (19)$$

假设 A^* 为上述优化问题的最优解, 通过 $Y = AX$ 可知上述优化问题的最优解为 $A^* = YX^+$, X^+ 为 X 的伪逆矩阵。 X^+ 的伪逆矩阵可以通过 $X^+ = V\Sigma^{-1}U^T$ 求解, $U\Sigma V^T$ 为 X 的瘦形奇异值分解。样本 X 的主要成分和误差部分分别为 A^*X 和 $X - A^*X$ 。因为 A 反应的是污染样本和干净低秩恢复之间的一种映射关系, 所以当给定一个测试样本 y , A^*y 即为测试样本 y 的低秩恢复。

图 2 是 AR 数据库中部分测试样本图像经过低秩投影矩阵恢复后的图像, 可以看到通过将测试样本投影到低秩投影矩阵, 测试图像中的遮挡区域得到一定程度的消除, 接下来就可以开始进一步地降维和分类操作, SWLRR 的整体流程如算法 2 所示。

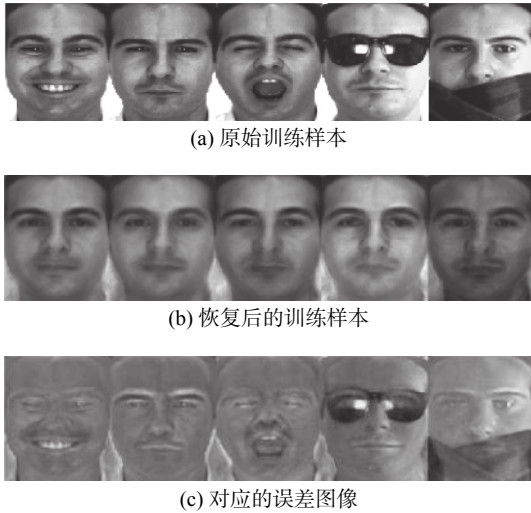


图 2 测试样本经过矩阵 A 投影后的恢复结果
Fig. 2 Recovery results using low-rank projection A

算法 2 结构约束的低秩投影稀疏算法

输入 C 类训练样本 $X = [X_1 X_2 \cdots X_N] \in \mathbf{R}^{m \times T}$, 测试样本 $y \in \mathbf{R}^m$, 正则化参数 λ 和 β , 稀疏表示的参数 src_λ 。

输出 $\text{identity}(y) = \arg \min_i (e_i)$ 。

- 1) 通过算法 1 得到所有训练样本的结构化判别秩 Z^* ;
- 2) 得到训练样本的恢复数据 $Y = XZ^*$;
- 3) 计算低秩投影矩阵 $A^* = YX^+$;
- 4) 测试样本 y 投影到相应子空间 $y_r = A^*y$;
- 5) 计算 Y 的主分量 W , $W = \text{PCA}(Y)$;

6) 训练样本恢复后的数据 Y 和测试样本恢复后的数据 y_r 分别投影到 W , 即 $D = W(Y)$, $y_p = W(y_r)$;

7) 求解 $\min_\alpha \|y_p - D\alpha\|_2^2 + \text{src}_\lambda \|\alpha\|_1$ 优化问题;

8) 计算每个类别对应的残差: $e_i = \|y_p - D_i\alpha_i\|_2^2$ 。

4 实验结果与分析

为了验证 SWLRR 的有效性, 本文将 SWLRR 和一些已经提出的经典算法如 DLRR、SRC、LRMR、RRC^[8]、SVM^[25-27] 进行了对比。所有算法均使用 SRC 算法进行分类。实验中 SWLRR 和 DLRR 算法引入了低秩投影思想。实验分别在 CMU PIE、AR 和 Extended Yale B 人脸数据库上进行。

我们使用有光照、表情变化以及饰物遮挡的人脸图像对 SWLRR 算法进行测试, 实验中所有训练样本和测试样本的污损类型都是相同的, 且每一次样本选择都是随机的。实验涉及 4 个重要参数, 包括 3 个 SWLRR 的权重参数 α 、 β 、 λ 和 1 个 SRC 参数 src_λ , 参数值通过多次实验确定。在 AR^[28]、Extended Yale B^[29-30]、CMU PIE^[31] 数据库参数均设为 0.05。

实验在 CPU 为 Intel core i5-6500 @3.20 GHz, 内存为 12.0 GB, 操作系统为 Windows 7, MATLAB 版本为 MATLAB R2015a 的环境下进行。

4.1 无遮挡的人脸识别实验

4.1.1 Extended Yale B 数据库

Extended Yale B 数据库由 38 个人的 2 414 张人脸图片组成, 每个人大约有 59~64 张不同的光照环境下的图片。在实验中, 每张人脸图片大小为 192 像素×168 像素。图 3(a) 展示了 Extended Yale B 数据库中某类的少量样本。在 Extended Yale B 数据库我们进行了 2 次无遮挡实验, 分别在每一类中随机选择 16 和 32 个样本作为训练样本, 其余作为测试样本。每个实验重复 10 次, 取 10 次结果的均值为最终结果。特征维度选择为 25、50、75、100、200 和 300。训练样本个数为 16 和 32 的实验结果如表 1、2 所示。

两组实验结果显示以上所有算法的识别率都随着图像特征维度的增加而增加, 这是因为相对较高的维度提供了更多的图像信息, 从而提高了识别性能。而且在维度相同时, SWLRR 的识别率远高于其他算法, 尤其是在特征维度较低时, 本文提出的方法更加有优势。例如: 特征维度为 25 时, 以上的 2 组实验中 SWLRR 的识别率高达

92.41% 和 97.75%, 远远高于其他算法。实验结果可以证实, SWLRR 可以较好地解决样本中存在不同的光照和表情的问题。

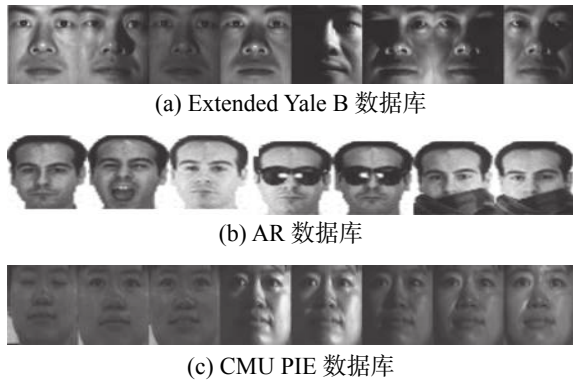


图3 实验中用到的样本图像

Fig. 3 Images used in our experiments

表1 Extended Yale B 数据库在无遮挡条件下不同维度的算法识别率 (16 训练样本)

Table 1 The recognition rate of different dimensions in Extended Yale B database without occlusion(16 training samples) %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	92.41	86.27	73.44	75.32	77.51	71.54
50	95.48	91.53	85.32	86.34	86.75	77.18
75	95.82	92.85	89.0	89.78	89.46	77.49
100	95.78	93.79	90.65	90.91	91.04	80.33
200	95.81	95.56	93.89	93.74	93.86	81.99
300	95.79	95.65	94.94	94.48	94.8	82.48

表2 Extended Yale B 数据库上在无遮挡条件下不同维度的算法识别率 (32 训练样本)

Table 2 The recognition rate of different dimensions in Extended Yale B database without occlusion(32 training samples) %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	97.75	92.88	80.08	82.98	86.77	80.35
50	99.45	96.89	91.59	92.35	93.51	87.08
75	99.42	97.26	94.27	95.79	95.09	89.09
100	99.39	97.9	95.8	96.94	96.14	90.2
200	99.39	98.89	97.58	98.02	97.79	91.37
300	99.42	99.13	98.23	97.98	98.4	91.82

4.1.2 AR 数据库实验

AR 数据库包含 126 个人的 4 000 多张人脸图片, 每个人有 26 张, 被分为两部分, 每部分由含有表情光照变化的 7 幅无遮挡图片、3 幅戴墨镜

图片和 3 幅戴围巾图片组成, 每幅图片大小被裁剪成 165 像素×120 像素, 图 3(b) 展示了 AR 数据库中某类的少量样本。实验中每人前半部分图片中的 7 张无遮挡图片作为训练样本, 后半部分中的 7 张无遮挡图片作为测试样本, 特征维度选择为 25、50、100、200、300, 对比结果如表 3 所示。从实验结果来看, SWLRR 在 AR 数据库上无遮挡条件的识别率也均高于其他算法。

表3 AR 数据库在无遮挡条件下不同维度的算法识别率

Table 3 The recognition rate of different dimensions in AR database without occlusion %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	75.71	71.00	64.29	69.86	69.14	60.71
50	87.57	85.14	81.29	85.71	82.57	68.0
100	90.57	89.14	89.29	90.14	90.42	72.29
200	92.71	88.43	92.14	93	92.57	73.71
300	93.14	88.57	93.14	93.57	93.14	74.00

4.1.3 CMU PIE 数据库实验

CMU PIE 数据库由 68 个人的 41 368 张图片组成, 所有图片在不同姿势、光照和表情条件下采集。本文选用编号为 C07 的子数据库用来实验, 其包含 68 个人的 1 629 张图片, 每人大约 24 张, 每张图片大小为 64×64, 图 3(c) 展示了 CMU PIE 数据库中某类的少量样本。实验中每类随机选择 12 张图片作为训练样本, 其余图片作为测试样本, 共进行 10 次实验, 取 10 次结果均值为最终结果。特征维度选择为 25、50、100、200、300, 对比结果如表 4 所示。

表4 CMU PIE 数据库上不同算法在无遮挡条件下的识别率

Table 4 The recognition rate of different dimensions in CMU PIE database without occlusion %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	93.39	82.60	79.32	81.65	78.51	75.19
50	94.58	90.97	89.14	90.53	88.17	79.10
100	94.75	93.16	92.55	92.83	90.42	81.18
200	94.76	93.98	93.43	93.34	90.30	82.50
300	94.84	94.05	93.73	93.37	90.01	82.74

从表 4 可以看出, 在 CMU PIE 数据库上 SWLRR 算法在不同维度下识别率同样远高于其他算法。在维度为 25 时, SWLRR 算法识别率为 93.39%, 高于 DLRR 算法将近 11%。但是, 随着维度的增加, 各种算法识别率的差异变得越来越小, 主要

是因为在低维度情况下,DLRR 算法缺乏结构化特征,数据的线性特征不足以分离不同子空间的样本,SWLRR 增强了不同类样本的结构性,进一步提高了样本的判别能力,从而提高了识别率。

4.2 有噪声的人脸识别实验

4.2.1 加入人工噪声的人脸识别

为了验证 SWLRR 算法的鲁棒性,首先在 Extended Yale B 数据库上进行添加随机高斯噪声的实验。实验中,每张图片大小为 192×168 像素。对整个数据库分别随机选择 10% 和 20% 比例的样本进行高斯噪声污染,污染比例为 10%,污染后,每类随机选择 32 个样本进行训练,剩余样本进行测试,每次实验重复 5 次取均值。在维度为 50、100、300 时对 2 种污染比例下不同算法进行比较,结果如表 5 所示。

表 5 Extended Yale B 数据库上不同算法在两种比例噪声污染下的识别率

Table 5 The recognition rate of different methods on the Extended Yale B database with two kinds of pixel corruptions %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
50	98.58	96.04	91.07	91.86	93.24	86.44
100	98.58	97.37	94.78	96.16	95.66	88.44
300	98.66	98.58	96.91	96.37	97.58	90.78
50	97.66	92.49	89.07	90.82	91.28	85.89
100	97.58	93.36	91.36	92.86	93.24	86.31
300	97.75	94.24	92.49	93.78	93.99	87.15

表 5 中,前 3 行和后 3 行分别是随机选择数据库中 10% 和 20% 比例的样本进行污染后,SWLRR 算法在该数据库上的识别率(不同特征维度下)。

4.2.2 有真实遮挡的人脸识别

本节进一步研究 SWLRR 算法在不同类型的面部遮挡情况下的性能,实验选用了难度较大的 AR 数据库,因为 AR 数据库中的图像会存在多种类型的遮挡。主要通过选取以下 2 种类型的遮挡来评估算法的鲁棒性。

1) 太阳镜:验证 SWLRR 在选取的训练样本和测试样本中均含有太阳镜遮挡时的性能,太阳镜大概遮挡了人脸的 20%。选择每一类前半部分中的 7 张中性图片(表情光照)加上随机选取的一个有太阳镜遮挡图片作为训练样本,则后半部分的 7 张中性图片和所有剩下的 5 张太阳镜图片作为测试样本(8 个训练样本,12 个测试样本)。

2) 太阳镜围巾混合情形:验证 SWLRR 在选

取的训练样本和测试样本中均含有太阳镜和围巾遮挡时的性能。每一类前半部分中的 7 张中性图片(表情光照)和随机选取的一个有太阳镜遮挡图片、一个有围巾遮挡图片作为训练样本,则后半部分的所有图片和前半部分剩下的 2 张含有太阳镜和 2 张含有围巾的图片作为测试样本(9 个训练样本,17 个测试样本)。

实验中,对类型 1) 进行 3 次实验,每次选择不同的遮挡图片作为训练样本,最后取 3 次分类结果的均值;对类型 2),进行 9 次实验,每次选择不同组合的太阳镜样本和墨镜样本作为训练样本,最后取 9 次结果的均值。特征维度选择为 25、50、100、200 和 300。以下列举了各种算法在类型 1) 和 2) 时的识别率,如表 6、表 7 所示。

表 6 AR 数据库上不同算法在太阳镜遮挡条件下的识别率

Table 6 The recognition rate of different methods on the AR database with the occlusion of sunglasses %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	71.69	70.14	60.58	65.72	63.69	58.58
50	84.92	81.61	77.31	80.92	80.33	66.11
100	91.19	89.58	84.89	87.94	86.53	70.14
200	91.55	91.00	89.25	90.36	89.61	72.03
300	91.60	91.39	90.56	91.00	90.89	72.17

表 7 AR 数据库上不同算法在混合遮挡条件下的识别率

Table 7 The recognition rate of different methods on the AR database with mix occlusion %

特征维度	SWLRR	DLRR	SRC(PCA)	LRMR	RRC	SVM
25	66.73	65.96	52.73	60.0	56.0	50.45
50	84.10	80.12	70.69	77.08	74.39	60.29
100	88.96	87.33	81.51	85.27	83.84	64.61
200	89.37	88.86	86.84	88.49	87.96	66.94
300	89.36	88.83	88.80	88.94	89.55	67.43

从表 6、表 7 可以看出,在样本存在真实遮挡的情形下,SWLRR 算法在不同维度时,性能仍然优于其余所有算法,这表明 SWLRR 算法在样本存在真实遮挡时有着较好的鲁棒性。

5 结束语

本文提出了用于人脸识别的结构化加权稀疏低秩恢复算法(SWLRR),主要解决了训练样本和测试样本同时存在污染导致无法正确分类的问题。SWLRR 首先对低秩系数进行权重和结构化约束,继而通过移除训练样本和测试样本中的污

染,有效减少了样本中的污染对实验结果造成的负面影响。因此 SWLRR 算法样本在有无遮挡的情况下都有着较为突出的性能。在 AR、Extended Yale B、CMU PIE 数据库上的实验验证了 SWLRR 算法在不同情况下的有效性和对噪声的鲁棒性。下一步将尝试将本文思想与其他解决样本中存在污染的算法结合,进一步提升算法性能。

参考文献:

- [1] TURK M, PENTLAND A. Eigenfaces for recognition[J]. *Journal of cognitive neuroscience*, 1991, 3(1): 71–86.
- [2] BELHUMEUR P N, HESPAHIA J P, KRIEGMAN D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection[J]. *IEEE transactions on pattern analysis and machine intelligence*, 1997, 19(7): 711–720.
- [3] LIU Chengjun, WECHSLER H. Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition[J]. *IEEE transactions on image processing*, 2002, 11(4): 467–476.
- [4] HE Xiaofei, YAN Shuicheng, HU Yuxiao, et al. Face recognition using Laplacianfaces[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2005, 27(3): 328–340.
- [5] 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.
- [6] MIN R, DUGELAY J L. Improved combination of LBP and sparse representation based classification (SRC) for face recognition[C]//*Proceedings of 2011 IEEE ICME*. Barcelona, Spain, 2011: 1–6.
- [7] CHEN C F, WEI C P, WANG Y C F. Low-rank matrix recovery with structural incoherence for robust face recognition[C]//*Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, USA, 2012: 2618–2625.
- [8] YANG Meng, ZHANG Lei, YANG Jian, et al. Regularized robust coding for face recognition[J]. *IEEE transactions on image processing*, 2013, 22(5): 1753–1766.
- [9] ZHANG Lei, YANG Meng, FENG Xiangchu. Sparse representation or collaborative representation: which helps face recognition?[C]//*Proceedings of 2011 ICCV*. Barcelona, Spain, 2011: 471–478.
- [10] DENG Weihong, HU Jiani, GUO Jun. Extended SRC: undersampled face recognition via intraclass variant dictionary[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2012, 34(9): 1864–1870.
- [11] YANG Meng, ZHU Pengfei, LIU Feng, et al. Joint representation and pattern learning for robust face recognition[J]. *Neurocomputing*, 2015, 168: 70–80.
- [12] CANDÈS E J, LI Xiaodong, MA Yi, et al. Robust principal component analysis[J]. *Journal of the ACM*, 2011, 58(3): 11.
- [13] LIU Guangcan, LIN Zhouchen, YAN Shuicheng, 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.
- [14] MA Long, WANG Chunheng, XIAO Baihua, et al. Sparse representation for face recognition based on discriminative low-rank dictionary learning[C]//*Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, USA, 2012: 2586–2593.
- [15] ZHANG Yangmuzi, JIANG Zhuolin, DAVIS L S. Learning structured low-rank representations for image classification[C]//*Proceeding of 2013 IEEE Conference on Computer Vision and Pattern Recognition*. Portland, USA, 2013: 676–683.
- [16] NGUYEN H, YANG Wankou, SHENG Biyun, et al. Discriminative low-rank dictionary learning for face recognition[J]. *Neurocomputing*, 2016, 173(3): 541–551.
- [17] CHANG Heyou, ZHENG Hao. Weighted discriminative dictionary learning based on lowrank representation [J]. *Journal of physics: conference series*, 2017, 90: 012009.
- [18] ZHANG Zheng, XU Yong, SHAO Ling, et al. Discriminative block-diagonal representation learning for image recognition[J]. *IEEE transactions on neural networks and learning systems*, 2018, 29(7): 3111–3125.
- [19] CHEN Jie, YI Zhang. Sparse representation for face recognition by discriminative low-rank matrix recovery[J]. *Journal of visual communication and image representation*, 2014, 25(5): 763–773.
- [20] COSTEIRA J P, KANADE T. A multibody factorization method for independently moving objects[J]. *International journal of computer vision*, 1998, 29(3): 159–179.
- [21] ZHUANG Liansheng, GAO Haoyuan, LIN Zhouchen, et al. Non-negative low rank and sparse graph for semi-supervised learning[C]//*Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, USA, 2012: 2328–2335.
- [22] LIN Zhouchen, LIU Risheng, SU Zhixun. Linearized alternating direction method with adaptive penalty for low-rank representation[J]. *Advance in neural information processing systems*, 2011: 612–620.
- [23] LIN Zhouchen, CHEN Minming, MA Yi. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[R]. Urbana-Champaign: University of Illinois at Urbana-Champaign, 2009.

- [24] BAO Bingkun, LIU Guangcan, XU Changsheng, et al. Inductive robust principal component analysis[J]. *IEEE transactions on image processing*, 2012, 21(8): 3794–3800.
- [25] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine learning*, 1995, 20(3): 273–297.
- [26] HEISELE B, HO P, POGGIO T. Face recognition with support vector machine: global versus component-based approach[C]//Proceedings Eighth IEEE International Conference on Computer Vision. Vancouver, BC, Canada, 2001: 688–694.
- [27] CHANG C C, LIN C J. Libsvm: a library for support vector machines[J]. *ACM transactions on intelligent systems and technology*, 2011, 2(3): 1–27.
- [28] MARTINEZ A, BENAVENTE R. The AR face database[R]. CVC Technical Report No.24. Barcelona: Universitat Autònoma de Barcelona, 1998.
- [29] GEORGHIADES A S, BELHUMEUR P N, KRIEGMAN D J. From few to many: illumination cone models for face recognition under variable lighting and pose[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2001, 23(6): 643–660.
- [30] LEE K C, HO J, KRIEGMAN D J. Acquiring linear subspaces for face recognition under variable lighting[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2005, 27(5): 684–698.
- [31] SIM T, BAKER S, BSAT M. The CMU pose, illumination, and expression database[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2003, 25(12): 1615–1618.

作者简介:



吴小艺,女,1994年生,硕士研究生,主要研究方向为人脸识别、稀疏低秩表示、字典学习。



吴小俊,男,1967年生,教授,博士生导师,主要研究方向为人工智能、模式识别、计算机视觉。研究成果获得省部级以上奖励5项。完成包括国防973子课题、IEEE智慧城市国际合作项目、国家自然科学基金项目和教育部重大科研课题研究项目。发表学术论文200余篇,被SCI检索50余篇、EI检索100余篇,出版学术著作5部。