

基于改进协同表示的二级分类人脸识别方法^①

施 志 刚

南通航运职业技术学院 管理信息系, 江苏 南通 226010

摘要: 基于协同表示分类(CRC)算法在实际应用中的效果, 考虑到样本局部相似性先验信息对分类识别的不同贡献, 构建加权矩阵, 并嵌入到 CRC 中, 称为加权 CRC. 为进一步改善人脸识别的性能, 设计了如下算法: 一种将加权 CRC 重复两次; 另一种则将其与线性表示分类(LRC)结合. 两种方法的共同特点为: 首先基于主成分分析(PCA)对所有图像样本进行降维, 以降低计算的复杂度; 其次都是在第一阶段的加权 CRC 中根据重构残差排序保留相关性较大的训练样本用于下一阶段的分类识别. 这种缩小分类目标的做法, 使识别更精确. 在 ORL, FERET 及 AR 人脸数据库上通过仿真验证了本文所提方法的有效性.

关 键 词: 协同表示分类; 样本局部相似性; 加权矩阵; 线性表示分类; 人脸识别

中图分类号: TP391.41

文献标志码: A

文章编号: 1673-9868(2017)01-0172-07

当今数字化信息时代, 随着互联网的迅猛发展, 各种信息资源的安全性是很重要的问题, 在很多场合都采取了访问控制的安全防护措施. 其中, 基于生理特征的身份鉴别, 如人脸识别、指纹识别等就因其实时性、便捷性等特点而得到广泛应用^[1-2]. 如何在复杂环境中对人脸检测和识别是目前人脸识别领域的研究内容, 其中最佳鉴别特征的提取与分类器设计更是该领域的热点课题. 随着压缩感知编码^[3]理论的提出, 一些研究人员发现特征^[4-11]的选择并不很重要. 假如能在高维空间对人脸图像有更准确的估计就可以获得更高的识别率.

于是, 近年来基于稀疏编码模型的人脸识别技术引起广泛关注. WRIGHT^[12]等最先提出基于稀疏表示分类(SRC)的人脸识别方法. 该方法由于对图像本身存在的噪声影响不敏感, 在识别方面有较强的鲁棒性. 围绕此模型, 很多学者作了大量深入的研究, 比如针对更为复杂的光照、遮挡等实际环境, 提出了在 SRC 中嵌入迭代加权系数的方法^[13]以及基于 Gabor 变换提取图像局部方向性特征的 SRC 算法^[14]等. 以上方法虽然在应用中有不错的效果, 但 SRC 基于最大似然估计的 l_1 -范数的系数求解, 由于需要迭代, 致使计算的复杂度较高. 为此, ZHANG^[15]等提出了用 l_2 -范数代替稀疏求解的 CRC. 此方法在分类识别时, 保证了测试样本与类内样本的误差足够小, 同时与类间样本的误差足够大, 使识别更加有效. 此外, NAS-EEM^[16]等将 LRC 引入, 同样可较为准确地估计人脸图像在高维空间的分布. 此算法简单、易实现, 在人脸识别应用中无论计算效率还是识别率都很好, 但对图像的要求较高, 易受噪声的干扰.

为进一步改善人脸识别方法的性能, 本文引入 CRC^[17-18], 并根据各训练样本与测试样本的误差构建加权矩阵权衡它们之间的相似度, 并将其嵌入到 CRC 中, 称为加权 CRC. 另外, 基于所有样本的协同表示在系数求解时需将二维图像转换为一维列向量, 从训练集的规模考虑, 一旦维数过大, 势必会大幅增加计算的复杂度, 从而降低运行效率. 因此首先基于 PCA 对所有图像样本降维, 然后利用 CRC 与 LRC 的特点, 采取组合策略设计了两种二级分类方法以获得更好的识别效果, 分别为: 二级加权 CRC、加权 CRC 与

① 收稿日期: 2015-10-20

基金项目: 国家自然科学基金项目(61473159); 南通航运职业技术学院科技基金重点资助项目(HYKJ/2016A02).

作者简介: 施志刚(1980-), 男, 江苏南通人, 讲师, 主要从事图像处理与模式识别算法研究.

LRC 相结合. 它们在第一阶段都使用加权 CRC, 根据重构残差保留相关性较大的类用于下一阶段的分类识别. 区别在于第二种方法在第二阶段基于 LRC 判别测试样本的归属. 两种方法通过阶段性缩小分类目标的做法, 可使分类更精确. 在 ORL, FERET 及 AR 人脸库上的实验验证了本文方法的有效性.

1 CRC 原理

基于压缩感知编码理论的 SRC 算法在人脸识别中因其鲁棒性较强而被广泛应用, 但由于其基于 l_1 -范数的系数求解^[19], 一味突出样本的稀疏性, 致使计算中不断迭代, 降低了算法的时效. 于是 ZHANG 等提出 CRC 方法, 此模型突出所有样本的协作性, 为降低稀疏度, 用 l_2 -范数代替以简化计算.

设有 C 类目标样本, 每类样本有 n_i 幅图像, 样本总数 $N = \sum_{i=1}^C n_i$, $\mathbf{X}_j^i$ 是第 i 类第 j 幅样本, 图像大小为 $m \times n$. 将 $\mathbf{X}_j^i$ 矢量化为 $\mathbf{x}_j^i \in \mathbb{R}^{m \times 1}$, 这样第 i 类训练样本组成的矩阵为 $\mathbf{X}_i = [\mathbf{x}_1^i, \dots, \mathbf{x}_{n_i}^i] \in \mathbb{R}^{m \times n_i}$, 从而构成完备的训练样本, 表示为 $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_C] \in \mathbb{R}^{m \times N}$. 设测试样本为 $\mathbf{Y} \in \mathbb{R}^{m \times n}$, 将 $\mathbf{Y}$ 矢量化为 $\mathbf{y} \in \mathbb{R}^{m \times 1}$.

CRC 中样本系数 $\boldsymbol{\alpha}$ 的求解由下式定义

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

其中 $\lambda \in (10^{-6}, 0.1)$ 是正则化参数, 以稳定重构误差和稀疏性.

系数 $\boldsymbol{\alpha}$ 可通过对(1)式求导得出, 即

$$\boldsymbol{\alpha} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y} \quad (2)$$

下式计算各类训练样本线性重构与测试样本 $\mathbf{y}$ 的残差 e_i , 即

$$e_i = \frac{\|\mathbf{y} - \mathbf{X}_i \boldsymbol{\alpha}_i\|_2}{\|\boldsymbol{\alpha}_i\|_2} \quad (3)$$

本文实验中文献[20]方法亦使用公式(3)计算残差.

最后依据 e_i 的最小值判断 $\mathbf{y}$ 的类别

$$\text{identity}(\mathbf{y}) = \arg \min_i \{e_i\} \quad (4)$$

2 LRC 原理

LRC 模型的实现是基于最小二乘法的线性表示算法, 该算法根据 $\mathbf{y}$ 与各类样本的重构误差决定其归属. 实现步骤如下, 对训练样本集的描述如前所述.

求解各类训练样本的重构系数 $\boldsymbol{\alpha} \in \mathbb{R}^{n_i \times 1}$, 即

$$\hat{\boldsymbol{\alpha}}_i = \arg \min_{\boldsymbol{\alpha}_i} \|\mathbf{y} - \mathbf{X}_i \boldsymbol{\alpha}_i\|_2 \quad (5)$$

用最小二乘法解出 $\hat{\boldsymbol{\alpha}}_i$, 即

$$\hat{\boldsymbol{\alpha}}_i = (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{y} \quad (6)$$

根据欧式距离计算 $\mathbf{y}$ 与每类训练样本的重构误差 β_i ,

$$\beta_i = \|\mathbf{y} - \mathbf{X}_i \hat{\boldsymbol{\alpha}}_i\|_2 \quad (7)$$

最后依据(8)式决定 $\mathbf{y}$ 的归属, 即

$$\text{identity}(\mathbf{y}) = \arg \min_i \{\beta_i\} \quad (8)$$

3 改进的协同表示二级分类方法

3.1 二级加权 CRC 方法

考虑到各训练样本 $\mathbf{x}_j^i$ 与测试样本 $\mathbf{y}$ 有一定的局部相似性, 那么它们对于分类识别的贡献取决于相似程度, 而这种相似度可通过欧氏距离获得, 定义 w_{ij} 为各训练样本 $\mathbf{x}_j^i$ 的权重值, 即

$$w_{ij} = e^{-\frac{\|\mathbf{y} - \mathbf{x}_j^i\|_2}{t}} \quad (9)$$

其中 t 为度量 $\mathbf{x}_j^i$ 与 $\mathbf{y}$ 误差的固值参数. 本文中 $t = \min\{\|\mathbf{y} - \mathbf{x}_j^i\|_2\}$.

以此构建对角加权矩阵, 即

$$\mathbf{M} = \begin{bmatrix} w_{11} & 0 & \cdots & 0 \\ 0 & w_{12} & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & w_{ij} \end{bmatrix} \quad (10)$$

将 $\mathbf{M}$ 嵌入到公式(1) 中, 得

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \{\|\mathbf{y} - \mathbf{X}\boldsymbol{\alpha}\|_2^2 + \lambda \|\mathbf{M}\boldsymbol{\alpha}\|_2^2\} \quad (11)$$

通过解析(11) 式求得 $\hat{\boldsymbol{\alpha}}$ 为

$$\hat{\boldsymbol{\alpha}} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{M})^{-1} \mathbf{X}^T \mathbf{y} \quad (12)$$

本文中 λ 取值为 0.01.

具体步骤如下:

Step 1: 将各类训练样本 $\mathbf{X}_j^i \in \mathbb{R}^{m \times n}$ 和测试样本 $\mathbf{Y} \in \mathbb{R}^{m \times n}$ 分别矢量化为 $\mathbf{x}_j^i \in \mathbb{R}^{m \times 1}, \mathbf{y} \in \mathbb{R}^{m \times 1}$.

Step 2: 利用 PCA 对 $\mathbf{x}_j^i$ 和 $\mathbf{y}$ 降维, 得 $\bar{\mathbf{x}}_j^i$ 和 $\bar{\mathbf{y}}$.

Step 3: 根据公式(9) 计算各训练样本 $\bar{\mathbf{x}}_j^i$ 的权值, 建立如公式(10) 所示的加权矩阵 $\mathbf{M}$ 嵌入 CRC 中, 如公式(11).

Step 4: 基于加权 CRC, 由公式(12) 求解编码系数 $\hat{\boldsymbol{\alpha}}$.

Step 5: 将 $\hat{\boldsymbol{\alpha}}$ 关联于各类训练样本的稀疏系数 $\boldsymbol{\alpha}_i$ 代入公式(3) 分别计算 $\bar{\mathbf{y}}$ 与每类训练样本 $\bar{\mathbf{x}}_j^i$ 的重构残差 e_i .

Step 6: 按残差 e_i 的升序排列, 从中选取前 S 类样本 $\bar{\mathbf{x}}_j^{\eta_s}$, 其中 $\eta_s \in [1, C]$.

Step 7: 根据公式(9) 计算 S 类训练样本 $\bar{\mathbf{x}}_j^{\eta_s}$ 的权值, 建立如公式(10) 所示的加权矩阵 $\bar{\mathbf{M}}$ 嵌入 CRC 中, 如公式(11).

Step 8: 将选出的 S 类训练样本 $\bar{\mathbf{x}}_j^{\eta_s}$ 重复步骤 Step 4 和 Step 5.

Step 9: 最终根据公式(4), 判断测试样本 $\bar{\mathbf{y}}$ 的类别.

3.2 加权 CRC 与 LRC 相结合方法

此方法与二级加权 CRC 类似, 只是在第二阶段用 LRC 分类识别, 相比前种方法, 识别性能更好, 算法具体步骤如下:

Step 1: 将各类训练样本 $\mathbf{X}_j^i \in \mathbb{R}^{m \times n}$ 和测试样本 $\mathbf{Y} \in \mathbb{R}^{m \times n}$ 分别矢量化为 $\mathbf{x}_j^i \in \mathbb{R}^{m \times 1}, \mathbf{y} \in \mathbb{R}^{m \times 1}$.

Step 2: 利用 PCA 对 $\mathbf{x}_j^i$ 和降维, 得 $\bar{\mathbf{x}}_j^i$ 和 $\bar{\mathbf{y}}$.

Step 3: 根据公式(9) 计算各训练样本 $\bar{\mathbf{x}}_j^i$ 的权值, 建立如公式(10) 所示的加权矩阵 $\mathbf{M}$. 嵌入 CRC 中, 如公式(11).

Step 4: 基于加权 CRC, 由公式(12) 求解编码系数 $\hat{\boldsymbol{\alpha}}$.

Step 5: 将 $\hat{\boldsymbol{\alpha}}$ 关联于各类训练样本的稀疏系数 $\boldsymbol{\alpha}_i$ 代入公式(3) 分别计算 $\bar{\mathbf{y}}$ 与每类训练样本 $\bar{\mathbf{x}}_j^i$ 的重构残差 e_i .

Step 6: 按残差 e_i 的升序排列, 从中选取前 S 类样本 $\bar{\mathbf{x}}_j^{\eta_s}$, 其中 $\eta_s \in [1, C]$.

Step 7: 将选出的 S 类训练样本 $\bar{\mathbf{x}}_j^{\eta_s}$ 分别根据公式(6) 求解重构系数 $\hat{\boldsymbol{\alpha}}_{\eta_s}$.

Step 8: 按公式(7) 分别计算测试样本 $\bar{\mathbf{y}}$ 与 S 类训练样本 $\bar{\mathbf{x}}_j^{\eta_s}$ 的重构误差 β_{η_s} .

Step 9: 根据公式(8), 判断测试样本 $\bar{\mathbf{y}}$ 的归属.

4 实验结果与分析

实验选用 MATLAB 7 作为仿真平台, 分别在 ORL, FERET 及 AR 人脸库上对本文提出的两种方法和 CFFR^[20]进行了性能比较. ORL 库有 40 人, 每人包含 10 幅不同表情、姿态、角度的人脸图片, 大小均为 112×92, 如图 1 所示. 实验取每人的前 6 幅, 共 240 幅作为训练样本, 余下的 160 幅作为测试样本. FERET 库比较庞大, 这里选择前 50 类, 每人仅取 7 幅不同的人脸图像, 这 7 幅图像的名称带有“ba”, “bd”, “be”, “bf”, “bg”, “bj”, “bk”标记. 该数据库人脸差异主要表现在光照、表情、角度等方面, 图片大小均为 80×80, 如图 2 所示. 其中每人的前 4 幅, 共 200 幅图片用作训练样本, 余下的 150 幅则为测试样本. AR 库共 120 人, 实验选其中 50 人, 每人除包含有不同表情、光照等差异的图像外, 还有不同程度的遮挡, 如图 3 所示. 图片大小均为 40×50. 取每人前 13 幅图像中非遮挡图像任意 4 幅, 遮挡图像随机 4 幅, 共 400 幅图像用作训练样本, 余下的 250 幅则为测试样本. 首先在 3 种数据库上分别将原始图像降维到 40, 对比了当选择不同的二级类别数 S 时, 3 种方法的识别效果(图 4—6).



图 1 ORL 库中某人图像示例



图 2 FERET 库中某人图像示例



图 3 AR 库中某人图像示例




图 4 ORL 库上 3 种方法在 S 变化时识别率比较




图 5 FERET 库上 3 种方法在 S 变化时识别率比较

从图 4、图 5、图 6 中看出本文提出的两种方法均比原算法^[20]在识别率上有不同程度地提升. 这是由于在协同表示时, 考虑了训练样本与测试样本的相似信息对识别的不同贡献, 通过构建加权矩阵权重不

同样本，嵌入在 CRC 中，使分类更有效. 比如在 ORL 库上，当 $S=C$ 时，原算法和方法一即等同于一级分类，识别率分别为 0.9 和 0.931 3，方法一相比原算法提高了近 4 个百分点；同样在 FERET 库上，当 $S=C$ 时，原算法识别率为 0.853 3，方法一识别率为 0.906 7，相比原算法提高了近 6 个百分点. 更重要的是在二级分类阶段，当选取的 $S \ll C$ ，方法一相比原算法可以达到最高识别率. 比如 ORL 库，当 $S=12$ ，方法一识别率达到最高，为 0.956 3，而原算法在 $S=18$ 时为最高，即 0.931 3. 另外在 FERET 库和 AR 库上，虽然原算法在 $S=2$ 时，识别率最高，分别为 0.886 7 和 0.984 0，但本文方法一依然可在此二级类别数下达到同等的识别率，并都在 $S=28$ 时，识别率最高，分别为 0.906 7 和 0.992 0. 因此足可证明在选取较少的 S 类目标样本的前提下，方法一的识别效果明显优于原算法.

另外，结合图 4、图 5 和图 6，不难发现当 S 变化时，识别效果还是有较大差别. 在 ORL 库上取 $S=6$ ，FERET 库上取 $S=10$ ，AR 库上取 $S=4$ 时，无论是原算法还是方法一的识别率都存在剧烈抖动，即有一个极低值. 起初以为只是个例，通过在试验中将所取原始图像的特征维数增多，发现抖动现象依然存在，且这个极低值会后移. 比如 ORL 库，将图像降维到 50，在 $S=8$ 时，出现极低值，如图 7 所示，FERET 库、AR 库亦同样如此. 然后随着 S 数增多，识别率逐渐提高，趋于稳定. 通过分析得出，算法抖动缘于通过 PCA 降维在一定程度上破坏了图像的结构性信息. 所以在某一低维特征，以上两种方法在图像有效信息缺失的情况下，应尽可能有完备的样本为前提，因为较少的 S 类样本协同表示在一定程度上会减弱 l_2 -范数的稀疏性约束. 相反，一旦维数增多，图像中用于判别的有效特征变多，较少 S 类样本稀疏表示的效果反而更好，这时方法一有较大优势. 倒是 S 数增多，识别率下降明显. 这也是图 7 中维数增多，极低值后移直至消失的原因. 因此，二级分类时，在某一特征维数下，只要选取适当数量的 S 类目标样本，还是能呈现出较高的识别率.

为解决上述算法在图像降维时出现的识别抖动问题，提出在第二阶段使用 LRC，通过各类训练样本分别表示及重构测试样本来分类. 从图 4、图 5 及图 6 可见方法二识别率较原算法及方法一都有一定提升，且识别效果更为平滑. 在 ORL 库和 FERET 库上的实验都在 $S=6$ 时取得最高识别率，分别为 0.962 5 和 0.913 3. 对于 AR 库，在 $S=2$ 时，识别率即可达到最高，为 0.988 0. 因此可以得出方法二在二级分类时，选取的目标样本类别数 S 满足 $S \ll C$ ，则很有可能获得更高的识别率.

接下来在 3 种数据库上分别比较本文方法二和其他方法在不同特征维数下的识别性能，如表 1—表 3 所示. 对于方法二，二级分类数取 $S=6$.

表 1 ORL 库上不同特征维数各方法识别性能对比

维数	WSRC ^[17]		VSCRC ^[18]		本文方法二	
	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s
20	93.13	0.013 7	80.00	0.077 0	95.00	0.013 7
30	91.87	0.015 8	83.75	0.078 6	93.75	0.015 3
40	93.13	0.016 3	86.88	0.085 1	96.25	0.015 8
50	93.13	0.015 7	89.38	0.083 3	94.37	0.016 8
60	95.00	0.016 3	89.38	0.085 6	96.25	0.016 8




图 6 AR 库上 3 种方法在 S 变化时识别率比较




图 7 ORL 库取不同特征维数两种方法识别率对比

表 2 FERET 库上不同特征维数各方法识别性能对比

维数	WSRC ^[17]		VSCRC ^[18]		本文方法二	
	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s
20	84.00	0.008 8	68.67	0.046 1	92.67	0.011 1
30	84.67	0.009 4	78.00	0.047 6	91.33	0.009 8
40	90.67	0.009 9	84.67	0.049 3	91.33	0.010 0
50	90.00	0.010 5	82.00	0.051 8	90.00	0.011 6
60	89.33	0.011 9	84.67	0.053 2	90.67	0.011 8

表 3 AR 库上不同特征维数各方法识别性能对比

维数	WSRC ^[17]		VSCRC ^[18]		本文方法二	
	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s	识别率/%	平均识别时间/s
20	96.40	0.050 6	86.80	0.322 7	98.00	0.054 2
30	98.80	0.051 9	95.60	0.324 0	98.80	0.055 6
40	99.20	0.053 9	98.00	0.334 3	98.80	0.056 7
50	99.20	0.056 6	98.40	0.336 9	98.80	0.058 9
60	99.20	0.059 7	98.40	0.363 5	98.80	0.060 9

从表 1—3 看出,在 ORL 和 FERET 库上,方法二在不同特征维数下的平均识别率均高出 WSRC1~3 个百分点,识别时间相差不多,均在 0.01 s 左右.而 VSCRC 方法在低维特征下识别率较低,随着维数增多,识别率明显提高,但相比方法二,均低了 5~9 个百分点,识别时间更是接近其 6 倍.AR 库上,方法二和 WSRC 的平均识别率及识别时间几乎相同,VSCRC 方法在较高特征维数下同样保持高识别率,但识别时间比方法二和 WSRC 高出很多.原因在于 VSCRC 通过不同场景扩张每类样本数的做法,虽然能有效利用样本中的光照、表情等信息,从而获得较好的识别效果,但样本数增多无疑消耗系数求解的时间,使识别时间增加,导致效率下降.综合来看,3 种数据库上的实验表明方法二的识别性能更佳.

但是,有一点需要说明,基于本文方法的仿真实验是以选取的训练样本数多于测试样本为前提.一旦训练样本数少于测试样本,加权 CRC 与 LRC 的二级方法在识别率上相比其他两种方法就降低了很多,甚至无效了.分析得出是 LRC 算法的局限性,由于 LRC 是分别对每一类样本表示重构,如果训练样本少,那么在重构时误差就比较大,识别率自然降低,但是具体问题还有待进一步探究.

参考文献:

[1] ZHAO W Y, CHELLAPPA R, PHILLIPS P J, et al. Face Recognition: A Literature Survey [J]. ACM Computing Surveys, 2003, 35(4): 399—458.

[2] LI W J, WANG C J, ZHANG W, et al. A Survey of Face Recognition [J]. Pattern Recognition and Artificial Intelligence, 2006, 19(1): 58—66.

[3] CANDES E J, WAKIN M B. An Introduction to Compressive Sampling [J]. IEEE Signal Processing Magazine, 2008, 25(2): 21—30.

[4] TURK M, PENTLAND A. Eigenfaces for Recognition [J]. Cognitive Neuroscience J, 1991, 3(1): 71—86.

[5] BELHUMEUR V, HESPANHA J, KRIEGMAN D. Eigenfaces vs Fisherfaces: Recognition Using Class Specific Linear Projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711—720.

[6] FISHER R A. The Use of Multiple Measurements in Taxonomic Problems [J]. Annals of Eugenics, 1936, 22(2): 178—188.

[7] 周丽芳,房 斌,李伟生,等.一种自适应的 EDTLBP 人脸识别方法 [J]. 重庆邮电大学学报(自然科学版), 2013, 25(2):192—196.

[8] 杨 勇,田 侃.基于 Gabor 特征和 EHMM 的人脸识别方法 [J]. 重庆邮电大学学报(自然科学版), 2011, 23(3): 355—362.

[9] 施志刚.一种基于类间类内双权重图像分块 PCA 的人脸识别技术 [J]. 杭州师范大学学报(自然科学版), 2014, 13(1):

- 89—93.
- [10] 施志刚. 一种基于分块差图像的 2DPCA 人脸识别方法 [J]. 内蒙古师范大学学报(自然科学汉文版), 2015, 44(3): 380—384.
- [11] 晏 勇. 基于 SKLLE 和 SVM 的人脸表情识别 [J]. 西南师范大学学报(自然科学版), 2014, 39(1): 55—60.
- [12] WRIGHT J, YANG A Y, GANESH A, et al. Robust Face Recognition via Sparse Representation [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210—227.
- [13] YANG M, ZHANG L, YANG J, et al. Regularized Robust Coding for Face Recognition [J]. IEEE Trans on Image Processing, 2013, 22(5): 1753—1766.
- [14] YANG M, ZHANG L. Gabor Feature Based Sparse Representation for Face Recognition with Gabor Occlusion Dictionary [C]// Proc of the 11th European Conference on Computer Vision, Berlin: Springer, 2010: 448—461.
- [15] ZHANG L, YANG M, FENG X C. Sparse Representation or Collaborative Representation: Which Helps Face Recognition? [C]// Proc of the IEEE International Conference on Computer Vision, Barcelona: IEEE, 2011: 471—478.
- [16] 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.
- [17] LU C Y, MIM H, GUI J, et al. Face Recognition via Weighted Sparse Representation [J]. Journal of Visual Communication & Image Representation, 2013, 24(2): 111—116.
- [18] 张哲来, 马小虎. 基于虚拟样本的协同表示人脸识别算法 [J]. 计算机应用研究, 2015, 32(11): 3518—3520.
- [19] 胡晨晓, 邹显春, 陈 武, 等. 基于稀疏表示的近邻传播聚类算法 [J]. 西南大学学报(自然科学版), 2014, 36(5): 220—224.
- [20] XU Y, ZHU Q, FAN Z Z, et al. Using the Idea of the Sparse Representation to Perform Coarse-to-Fine Face Recognition [J]. Information Sciences, 2013, 238(7): 138—148.

A Two-Stage Face Recognition Method Based on Improved Collaborative Representation Classification

SHI Zhi-gang

*Department of Management and Information, Nantong Vocational and
Technical Shipping College, Nantong Jiangsu 226010, China*

Abstract: Based on the effect of collaborative representation classification (CRC) algorithm in practical application and taking into account the different contributions of the samples' local similarity prior information in classification and identification, a weighted matrix is constructed in this article and embedded in CRC, called weighted CRC. In order to improve the performance of face recognition, two algorithms are designed: one is that the weighted CRC is repeated two times, and the other is that it combines with linear representation classification (LRC). What is common for the two methods lies in that firstly, they both reduce the image dimension based on principal component analysis (PCA), so as to reduce the complexity of the computation, and secondly, according to the reconstruction residuals based on weighted CRC in the first stage, large relatively training samples are sorted out for classification and recognition of the next stage. These approaches to reduce the classification targets make the recognition more accurate. The effectiveness of the proposed methods is verified by simulation on ORL, FERET and AR face database.

Key words: collaborative representation classification; samples' local similarity; weighted matrix; linear representation classification; face recognition

