

稀疏规则引导的由粗及细系数累积人脸识别算法^①

胡正平^{②*} 刘立真^{*} 李淑芳^{*} 孙德刚^{**}

(^{*}燕山大学信息科学与工程学院 秦皇岛 066004)

(^{**}山东华宇工学院电子信息工程学院 德州 253000)

摘 要 考虑到以训练样本作为字典未利用类间差异特征的不足,且利用最小残差判别函数分类时,各类残差可能因较接近而导致分类错误。针对此问题,从分类判别函数出发,提出稀疏规则引导的由粗及细系数累积人脸识别算法。首先,用所有训练样本作为字典表示测试样本,得到相邻最大类累积稀疏系数。进而,根据累积系数相对差别,对训练样本类别进行软约束,摒弃与测试样本相异甚远的类别,遴选候选类。最后,利用最大类稀疏系数累积作为判别函数,融合由粗及细的结果进行分类从而获得最终的识别率。该方法不仅充分利用系数的稀疏性,而且发挥候选类具有增强字典鉴别力的作用,从而取得较高的识别率。本文方法分别在 ORL、AR 和 GT(Georgia Tech Face Database)人脸数据库上进行了实验。

关键词 人脸识别,稀疏表示,稀疏分类,稀疏系数累积,信息融合

0 引 言

稀疏表示作为近年来处理信号的新方法,在模式识别领域备受关注,人脸识别在该领域被深入研究^[1-3]。然而,由于各种因素的影响,人脸识别仍是一个具有挑战性的任务。

2009 年 Wright^[4]等人提出应用稀疏表示原理,依据该原理解决人脸识别问题,利用所有训练样本构成的过完备字典线性表示测试样本,采用最小残差判别函数进行分类。从求解稀疏系数角度,文献[5]提出基于子空间的有向结构稀疏表示和字典学习算法,提高稀疏表示编码质量,为求解稀疏系数提供了新思路。文献[6]提出利用非负稀疏低秩表示分类的人脸识别,稀疏的约束条件增添了识别信息,低秩矩阵可利用数据的全部结构,非负性确保了稀疏系数更好地反映数据的独立性。从扩展训练样

本角度,文献[7]利用原始样本产生其对称结构,利用原有图像和所生成图像完成协作表示人脸识别。从分类判决函数角度,部分学者利用系数的稀疏性,提出新的判决函数规则,且取得了较佳的结果^[8,9]。

许多学者依据稀疏表示原理用全局学习方法和局部学习方法对人脸识别算法进行研究。全局学习方法是应用所有类的训练样本完成训练的变换方法^[10,11]。文献[12]提出基于稀疏表示改进的完备字典人脸识别算法,利用特征融合构造线性有鉴别力的完备字典,增加类间离散度减少类内离散度且增强字典的鉴别能力,从而提高了分类判别能力。文献[13]提出基于非负平滑 L_0 范数的系数加权稀疏表示分类算法,训练样本能够更好地表示测试样本,同时利用它与每个训练样本间的交互信息获得权重从而加速算法的收敛性。文献[14]提出基于嵌入式稀疏字典学习算法,解决特征和字典分开学习的问题,同时利用字典学习和降维处理使类间和

① 国家自然科学基金(61771420)和河北省自然科学基金(F2016203422)资助项目。
② 男,1970 年生,博士,博士生导师,教授;研究方向:模式识别;联系人,E-mail: hzp@ysu.edu.cn
(收稿日期:2018-01-29)

类内稀疏系数距离界限更加明确,原数据结构的字典学习能力加强,获得更好的识别信息从而提高分类能力。局部学习方法仅应用训练样本子空间而不是全部的训练样本对测试样本进行分类识别。文献[15]提出基于局部约束模型的局部子空间平滑对齐人脸识别,利用局部子空间的非线性结构解决利用具有鉴别性的局部外观模型构造嵌入式点分布模型的问题。文献[16]提出基于 L_{21} 范数的 Fisher 有识别力的稀疏表示人脸识别,基于 Fisher 准则利用核范数约束系数矩阵,提供了更强的鉴别能力。文献[17]提出流形正则化局部稀疏表示人脸识别算法,将稀疏表示的编码向量构建成组稀疏,既控制个人稀疏又保证局部相似,同时利用同伦算法优化模型使权重参数更加稳定,此模型克服光照变化或者遮挡带来的识别困难,提高了识别率。文献[18]提出基于稀疏表示的局部结构人脸识别,将人脸图像分成局部结构,且每个局部结构被分成重叠块构成线性子空间,然后将每个块进行分类,最后融合分类结果得出分类精度。

稀疏表示模型重点在字典中找到测试样本的最佳线性组合,且不同训练样本线性表示测试样本的作用不尽相同,训练样本的稀疏系数越大,就证明这

些训练样本可以足够地表示测试样本。如果从全部训练集中筛选出可以足够表示测试样本的训练集会有更好的性能吗?就此问题,本文将稀疏系数累积判决函数和局部学习方法相结合,提出基于稀疏规则引导的由粗及细稀疏系数累积人脸识别算法。首先利用稀疏规则得到相邻最大类累积稀疏系数,然后利用累积系数关系软约束训练集,摒弃与测试样本距离较远的训练集类别得到候选类,最后利用最大类稀疏系数累积作为判别函数,融合由粗及细的前后结果获得最终分类判别。

1 稀疏规则引导的由粗及细系数累积整体结构组成

本文提出的方法如图 1 所示。首先,用所有训练样本作为字典线性表示测试样本,得到相邻最大类累积稀疏系数。然后,进行由粗及细过程,择选分类模式。若相邻最大类累积稀疏系数比值满足阈值要求,直接分类判别;否则,从全部训练样本集遴选前 S 个候选类得到局部训练样本集进而线性表示测试样本;最后,利用最大类累计稀疏系数作为判别函数,融合由粗及细的结果进行分类判别。




图 1 系统组成框图

2 稀疏规则引导的由粗及细系数累积人脸识别算法

2.1 稀疏表示分类原理

不妨设含有 L 类共 n 个 m 维的训练集,则第 i

类训练样本的集合可表示为

$D_i = [v_{i,1}, v_{i,2}, \dots, v_{i,n_i}] \in R^{m \times n_i}$ 。若测试样本 $y \in R^m$ 属于第 i 类, y 由训练样本 D_i 线性组合如下:

$$y = a_{i,1}v_{i,1} + a_{i,2}v_{i,2} + \dots + a_{i,n_i}v_{i,n_i} \tag{1}$$

式中系数 $a_{i,j} \in R, j = 1, 2, \dots, n_i$ 。

将所有类的训练样本组合成字典矩阵,可表示为

$$\begin{aligned} \mathbf{D} &= [\mathbf{D}_1, \dots, \mathbf{D}_L] \\ &= [v_{1,1} \dots v_{1,n_L}, v_{2,1} \dots v_{2,n_L}, \dots, v_{L,1} \dots v_{L,n_L}] \in R^{m \times n} \end{aligned} \quad (2)$$

故 y 可以由 $\mathbf{D}$ 线性表示为:

$$y = \mathbf{D}\alpha \in R^m \quad (3)$$

其中 $\alpha = [0, \dots, 0, a_{i,1}, \dots, a_{i,n_i}, 0, \dots, 0]^T \in R^n$ 为稀疏系数。 α 中对应第 i 类样本数值不为 0, 其余均为 0, 故 α 为稀疏的系数向量。

在人脸识别系统中,一般情况下 $m < n$, 故 $y = \mathbf{D}\alpha$ 对应的方程组是欠定系统, α 的解不唯一。考虑到 α 为稀疏的, 求解 $y = \mathbf{D}x_0$ 的结果, 可以转化为 L_0 优化问题:

$$\hat{\alpha} = \operatorname{argmin} \|\alpha\|_0 \text{ s.t. } \mathbf{D}\alpha = y \quad (4)$$

但是式(4) L_0 范数最小化求解是一个 NP-hard 问题, 可通过凸松弛, 转化为求解 L_1 最小化问题:

$$\hat{\alpha} = \operatorname{argmin} \|\alpha\|_1 \text{ s.t. } \mathbf{D}\alpha = y \quad (5)$$

但在实际问题中总是存在噪声影响, 将噪声的误差项设定为 ε , 则式(5)过程表示为

$$\hat{\alpha} = \operatorname{argmin} \|\alpha\|_1 \text{ s.t. } \|\mathbf{D}\alpha - y\|_2 \leq \varepsilon \quad (6)$$

求解上式, 可以得到系数向量 $\hat{\alpha} \in R^n$ 。

重构测试样本, 如下所示:

$$\hat{y}_i = \mathbf{D}\delta_i(\hat{\alpha}) \quad (7)$$

由此, 可得到每类对测试图像进行稀疏逼近的残差为 $r_i(y)$:

$$r_i(y) = \|y - \mathbf{D}\delta_i(\hat{\alpha})\|_2 \quad (8)$$

最终, 利用最小稀疏逼近残差的进行分类, 判别过程可表示为

$$\operatorname{identity}(y) = \operatorname{argmin}_i r_i(y) \quad (9)$$

3.2 稀疏系数累积判决函数分类原理

由式(9)可知, 最小残差函数判决准则根据各类残差大小进行判别分类, 各类残差可能因为较接近而导致分类错误。考虑到稀疏表示系数 α 反映测试样本与每个训练样本之间的相似性, 采用各类系数累积函数作为判决函数:

$$\operatorname{Identity}(y) = \operatorname{argmax}_{l \in \{1, 2, \dots, L\}} \mathbf{1}^T \alpha^l \quad (10)$$

其中, $\mathbf{1}^l$ 是一个全 1 的列向量, α^l 是第 l 类训练样本对应系数。当两类残差相接近的时候, 采用最大类

累积系数作为判决函数可较易得到正确分类, 从而改善因残差接近而带来的错误分类的问题。

2.3 基于稀疏规则引导的由粗及细系数累积人脸识别算法

2.3.1 稀疏系数累积模型

假设有 L 类共 n 个训练样本, 且每个样本被假设成一维列向量。用所有训练样本做字典表示测试样本:

$$y \approx \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n \quad (11)$$

其中, $\alpha_i (i = 1, 2, 3, \dots, n)$ 是 x_i 的系数。式(11)表明测试样本能近似地被各类训练样本线性表示。

接着, 将“ $\approx$ ”改为“ $=$ ”, 式(11)变为下式:

$$y = X\mathbf{A} \quad (12)$$

其中, $X = (x_1, x_2, \dots, x_n)$, $\mathbf{A} = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$ 。

然后, 用下式求解 $\mathbf{A}$:

$$\mathbf{A} = (X^T X + \mu \mathbf{I})^{-1} X^T y \quad (13)$$

其中, X 是所有的训练样本降维后的图像, y 是测试样本, μ 是正常数, $\mathbf{I}$ 是单位矩阵。由式(13)求出所有的训练样本的系数矩阵 $\mathbf{A}$ 。

接着, 累积各类的稀疏系数, 且将类稀疏系数累积值按降序排列。假设第 $k (k \in L)$ 类的稀疏系数累积值如下式:

$$A_k = \sum_{m=p}^q \alpha_m \quad (14)$$

A_k 越大说明第 $k (k \in L)$ 类的训练样本在表示测试样本时贡献越大, 式(14)中, $p, p+1, p+2, \dots, q$ 表示 A_k 中的第 $p, p+1, p+2, \dots, q$ 的组成成分。用 $A_{q_1}, A_{q_2}, A_{q_3}, \dots, A_{q_L}$ 分别表示 $L_{q_1}, L_{q_2}, L_{q_3}, \dots, L_{q_L}$ 的类的稀疏系数累积值。假设

$$A_{q_1} \geq A_{q_2} \geq A_{q_3} \dots A_{q_L} \quad (15)$$

相邻两个最大类稀疏系数累积值的比值如下:

$$T = \frac{A_{q_1} - A_{q_2}}{A_{q_1}} \quad (16)$$

其中, A_{q_1} 是最大类稀疏系数累积, A_{q_2} 是次大稀疏系数累积。

2.3.2 “由粗及细”分类模型

根据 2.3.1 节稀疏系数累积模型对全部训练样本集进行软约束。即获得的相邻最大类稀疏系数累积值的比值越大, 证明次大类累积稀疏系数与最大类累积稀疏系数差别越大。针对测试图像的判别问

题,训练集的类型差异明显,全部训练集能够足够稀疏地表示测试图像,那么就利用系数累积判别函数判别输出则可。

相反,若获得的相邻最大类稀疏系数累积值的比值较小,则易出现误判现象。那么就摒弃与测试样本相异甚远的类别,利用式(15)筛选出前 S 个候选类,利用“由粗及细”模式,实现分类判别。

利用前 S 个候选类的训练样本做字典:

$$y \approx d_1 t_1 + \dots + d_M t_M \tag{17}$$

其中, M 是来自前 S 个候选类的训练样本数量, $t_i (i = 1, 2, \dots, M)$ 表示 S 类的训练样本, $d_i (i = 1, 2, \dots, M)$ 是 t_i 的稀疏系数。

接着,改写式(17)为

$$y = GB \tag{18}$$

其中, $B = [d_1, d_2, \dots, d_M]^T, G = [t_1, t_2, \dots, t_M]$ 。

然后,求解系数矩阵 B :

$$B = (G^T G + \gamma I)^{-1} G^T y \tag{19}$$

其中, γ 是正常数。

最后,用式(14)求解每类稀疏系数累积值。

利用式(10)最大类累计稀疏系数作为判别函数,融合由粗及细的结果进行分类判别。虽然所有类的训练样本对于分类算法来说都是可以利用的,但是对于线性表示测试样本,每个训练样本的作用不尽相同。本文算法找到了测试样本的最佳线性组合,从而取得较高的识别率。

2.3.3 “由粗及细”算法的总结

- (1) 利用式(12),计算出所有样本的稀疏系数。
- (2) 利用式(14),计算类稀疏系数累积值,对类稀疏系数累积值按降序排序,得到次大类稀疏系数累积值和最大类稀疏系数累积值。
- (3) 利用式(16)求解相邻最大类稀疏系数累积值的比值,选择分类模式。
- (4) 用式(15)遴选训练样本标签为 $L_{q_1}, L_{q_2}, L_{q_3}, \dots, L_{q_s}$ 的前 S 个候选类。
- (5) 利用标签为 $L_{q_1}, L_{q_2}, L_{q_3}, \dots, L_{q_s}$ 前 S 类的训练样本做字典。用式(14)计算更新后的类累积稀疏系数。
- (6) 利用式(10)最大类累计稀疏系数作为判

别函数,融合由粗及细的结果进行分类判别。

3 实验结果分析与仿真

本文算法在 ORL 人脸数据库、AR 人脸数据库和 GT(Georgia Tech Face Database)人脸数据库进行一系列实验。采用最近邻分类器(NN)、最近子空间分类器(NS)、稀疏表示残差判别分类(SRC)、稀疏表示最大概率判别分类(SRC—MP)进行对比实验。

3.1 ORL 人脸数据库

ORL 人脸数据库包含 40 个人,每个人有 10 张人脸图像。图 2 是 ORL 数据库第 1 类样本部分图像。




图 2 ORL 人脸数据库示例图像

在实验中,每类选取 $N (=4, 5, 6)$ 幅图像进行训练,剩余的进行测试。ORL 人脸图像原始大小为 56×46 ,利用下采样对图像进行降维处理,降维后的图片大小为 12×10 。在算法进行前,将每个人脸图像转换成一维的列向量,并且进行归一化处理。当求解式(13)和式(19)时,将 μ 和 γ 设置成 0.01。

实验中根据相邻最大类累积稀疏系数比值设定阈值,本文选取的范围是 5% ~ 50%,其中间隔 5%。图 3 是相邻最大类累积稀疏系数比值曲线图。

不同的阈值使遴选的候选类数目不同,阈值越大,候选类数量越多,程序运行耗时越长,所以在相同识别率的情况下,选择较小的阈值。

实验证明,阈值为 5%、10%、15% 时平均分类错误率相同,阈值为 25%、30%、35%、40%、45%、50% 时平均分类错误率相同。所以实验结果只给出 5%、20%、25% 3 种情况的错误识别率图。图 4 是此 3 种情况下的分类判决错误率。




图3 两个最大类累积稀疏系数比值

由图4可以看出,随着遴选候选类的数目减少,错误率呈降低趋势,验证了“由粗及细”算法的有效性。从图4可以发现,当选择25%时,实验结果最佳。遴选合适的候选类,可以获得很好的识别效果。




图4 3种设定阈值的分类判别错误率

表1为最近邻分类器(NN)、最近子空间分类器(NS)、稀疏表示残差判别分类(SRC)、稀疏表示最大概率判别分类(SRC-MP)和本文方法在不同训练样本集下正确识别率。本文方法(min)是指利用全部类别得到的正确识别率,本文方法(max)是指遴选合适候选类得到的正确识别率。训练样本越多鉴别信息越多,由表1可以看出,本文方法运用由粗及细的稀疏过程和最大系数累积判别函数,判别性能优于其他算法。

表1 ORL人脸数据库几种方法识别率比较

算法	$N = 4$	$N = 5$	$N = 6$
NN	89.75%	91.00%	92.74%
NS	91.12%	92.08%	93.00%
SRC	94.58%	94.00%	94.38%
SRC-MP	94.17%	94.50%	95.00%
本文方法(min)	94.17%	93.50%	95.00%
本文方法(max)	96.25%	96.50%	96.88%

3.2 AR人脸数据库

AR人脸数据库包含120个人,每个人有14张人脸图像。图5是AR数据库第1类训练样本部分图像。

实验中,每类选取 $N(=6,7,8)$ 幅图像进行训练,剩余图像进行测试。AR人脸图像原始大小为 50×40 ,利用下采样对图像降维处理,降维后的图像大小为 12×10 。在算法进行前,将每个人脸图像转换成一个一维的列向量,并且用L2范数进行归一化处理。



图5 AR人脸数据库示例图像

实验中根据相邻最大类累积稀疏系数比值选取阈值范围是5%~50%,其中间隔5%。图6是两类最大累积稀疏系数比值曲线图。

实验证明,阈值为25%、45%、50%时平均分类错误率相同,阈值为30%、35%、40%时平均分类错误率相同。所以实验结果只给出5%、10%、15%、20%、25%、30%6种情况的结果。图7是此6种情况下的分类判别错误率。

由图7可以看出,筛选出的候选类数目越少,错误率越低,有效地发挥“由粗及细”的作用。从图7




图 6 两个最大类累积稀疏系数比值




图 7 6 种设定阈值的错误率

表 2 AR 人脸数据库几种方法识别率比较			
算法	$N = 6$	$N = 7$	$N = 8$
NN	64.79%	70.95%	83.33%
NS	69.89%	74.52%	87.08%
SRC	74.52%	78.85%	88.05%
SRC-MP	74.88%	78.52%	88.89%
本文方法 (min)	76.31%	79.69%	88.61%
本文方法 (max)	78.22%	80.73%	96.53%

3.3 GT 人脸数据库

GT (Georgia Tech Face Database) 人脸数据库包含 50 个人, 每个人有 15 张人脸图像。图 8 是 GT 数据库第 1 类训练样本部分图像。

中可以发现, 当选择 25% 的时候, 实验的效果最好。选择合适的候选类时, 可以获得很好的识别效果。

表 2 为 NN、NS、SRC、SRC-MP 和本文方法在不同训练样本下的结果。本文方法 (min) 是指利用全部类别得到的正确识别率, 本文方法 (max) 是指选择合适候选类得到的正确识别率。

由表 2 可以看出, 训练样本数量不同识别率不同, 训练样本越多鉴别信息越多。本文方法运用由粗及细的稀疏算法过程和最大系数累积判别法, 不仅充分利用系数的稀疏性, 而且发挥候选类具有增强字典鉴别力作用, 从而取得较高的识别率。



图 8 GT 人脸数据库示例图像

在实验中, 每类选取 $N (=6, 7, 8)$ 幅图像进行训练, 其余图像进行测试。所有图像进行灰度化处

理,降维后的图片大小为 20×15 。

实验中设定阈值是根据相邻最大类累积稀疏系数比值选取,本文选取范围是 $5\% \sim 50\%$,其中间隔 5% 。图 9 是两类最大累积稀疏系数比值图。

实验证明,阈值为 25% 、 50% 时平均分类错误率相同,阈值为 35% 、 40% 、 45% 时平均分类错误率相同。所以实验结果只给出 5% 、 10% 、 15% 、 20% 、 25% 、 30% 、 35% 7 种情况的结果。图 10 是此 7 种阈值下的分类判决错误率。

由图 10 可以看出,随着候选类数量减少,判别错误率降低,验证了提出的“由粗及细”人脸识别算法的有效性。从图 10 中可以发现,当选择 25% 时,实验的结果最佳。




图 9 最大两类累积稀疏系数比值




图 10 7 种设定阈值下的错误率

表 3 为 NN、NS、SRC、SRC-MP 和本文方法在不同训练样本下的正确率。本文方法 (min) 是指利用全部类别得到的正确识别率,本文方法 (max) 是指选择合适候选类得到的正确识别率。由表 3 可以看出,本文方法利用由粗及细思想和最大系数累积判别函数,判别性能优于其他算法。

表 3 GT 人脸数据库几种方法识别率比较

算法	$N = 6$	$N = 7$	$N = 8$
NN	62.11%	63.75%	65.12%
NS	62.33%	64.80%	66.02%
SRC	64.88%	66.75%	67.12%
SRC-MP	65.55%	67.25%	69.42%
本文方法 (min)	62.89%	66.00%	66.86%
本文方法 (max)	69.78%	72.75%	75.72%

4 结 论

不同训练样本线性表示测试样本的作用不尽相同,本文针对从全部训练集中筛选出可以足够表示测试样本的训练集是否效果更佳的问题,提出稀疏规则引导的由粗及细系数累积人脸识别算法。首先利用稀疏规则获得相邻最大类稀疏系数累积值;然后利用系数累积关系软约束训练集,利用由粗及细算法选择分类模式,摒弃与测试样本距离较远的训练集类别得到候选类;最后利用最大类稀疏系数累积作为判别函数,融合由粗及细的结果进行分类从而获得最终识别率。结果证明稀疏规则引导的由粗及细系数累积人脸识别算法的有效性,本文抓住稀疏表示模型的重点,在字典中找到了测试样本的最佳线性组合。

参考文献

- [1] Gao S, Jia K, Zhuang L, et al. Neither global nor local: regularized patch-based representation for single sample per person face recognition [J]. *International Journal of Computer Vision*, 2015, 111(3): 365-383
- [2] Zhang X Y. Simultaneous optimization for robust correlation estimation in partially observed social network[J]. *Neurocomputing*, 2016, 205: 455-462
- [3] Xu L, Wu X, Chen K, et al. Supervised within-class-similar discriminative dictionary learning for face recognition [J]. *Journal of Visual Communication and Image Representation*, 2016, 38: 561-572
- [4] 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
- [5] Nazzal M, Ozkaramanli H. Directionally-structured dictionary learning and sparse representation based on subspace projections[C]. In: Proceedings of the 23th IEEE Signal Processing and Communications Applications Conference (SIU), Malatya, Turkey, 2015. 1606-1610
- [6] Wang R, Chen C, Li J, et al. Face recognition via non-negative sparse low-rank representation classification [C]. In: Proceedings of the Natural Computation, Fuzzy

- Systems and Knowledge Discovery (ICNC-FSKD), Changsha, China, 2016:1609-1614
- [7] Liu Z, Pu J, Wu Q, et al. Using the original and symmetrical face training samples to perform collaborative representation for face recognition[J]. *Optik-International Journal for Light and Electron Optics*, 2016, 127(4): 1900-1904
- [8] 胡正平,彭燕,赵淑欢. 非最小平方误差局部-全局加权融合的稀疏表示遮挡人脸识别[J]. *模式识别与人工智能*, 2015, 28(7): 633-640
- [9] Cui M, Prasad S. Class-dependent sparse representation classifier for robust hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(5): 2683-2695
- [10] Feng Q, Zhu X, Pan J S. Global linear regression coefficient classifier for recognition [J]. *Optik-International Journal for Light and Electron Optics*, 2015, 126(21): 3234-3239
- [11] Zhu X B, Jin X, Zhang X Y, et al. Context-aware local abnormality detection in crowded scene[J]. *Science China Information Sciences*, 2015, 58(5): 1-11
- [12] Meng F, Tang Z, Wang Z. An improved redundant dictionary based on sparse representation for face recognition [J]. *Multimedia Tools and Applications*, 2017, 76(1): 1-18
- [13] Khorsandi R, Abdel-Mottaleb M. Classification based on weighted sparse representation using smoothed L0 norm with non-negative coefficients[C]. In: Proceedings of the International Conference on Image Processing (ICIP), Quebec City, Canada, 2015. 3131-3135
- [14] Chen Y, Su J. Sparse embedded dictionary learning on face recognition [J]. *Pattern Recognition and Artificial Intelligence*, 2017, 64: 51-59
- [15] Liu D, Tan X. Local subspace smoothness alignment for constrained local model fitting [J]. *Neurocomputing*, 2016, 214: 785-795
- [16] Zhao L, Zhang Y, Yin B, et al. Fisher discrimination-based $l_{2,1}$ -norm sparse representation for face recognition[J]. *The Visual Computer*, 2016, 32(9): 1165-1178
- [17] Wang L, Wu H, Pan C. Manifold regularized local sparse representation for face recognition [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2015,

25(4): 651-659

Transactions on Intelligent Systems and Technology

[18] Liu F, Tang J, Song Y, et al. Local structure-based sparse representation for face recognition [J]. *ACM*

(TIST), 2015, 7(1): 2-3

Coarse to fine coefficient accumulation face recognition based on sparse rules

Hu Zhengping^{*}, Liu Lizhen^{*}, Li Shufang^{*}, Sun Degang^{**}

(^{*} School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004)

(^{**} School of Electronic and Information Engineering, Shandong Huayu University of Technology, Dezhou 253000)

Abstract

The features of difference between classes are not used in the ordinary training sample dictionary and may lead to a wrong classification using the minimum residual as a decision function for sparse representation classification when the residual is approximate. In this case, proceeding from the decision rule of the classifier, the algorithm of coarse to fine coefficient accumulation face recognition based on sparse rules is proposed. Firstly, a linear combination of the training samples from all classes that is approximately equal to the test sample is determined, and the sparse coefficient accumulation of the most two adjacent categories is acquired. Second, according to the relative difference of sparse coefficient accumulation, we perform the soft constraints for all training samples and reject the classes which are far different from the test sample. Finally, the results of two kinds of classification model are combined and the sparse coefficient accumulation of each class is calculated for the final classification. This method not only makes full use of the sparsity of coefficient, but the candidate classes play a role in the discrimination of dictionary. In order to verify the effectiveness of our algorithm, experiments are conducted respectively in the ORL, AR, and GT(Georgia Tech) facial database.

Key words: face recognition, sparse representation, sparse classification, sparse coefficient of accumulation, Information fusion