

文章编号:1000-5862(2020)05-0472-06

一种动态剪枝的协同稀疏表示方法研究及应用

周俊星, 梁路*

(广东工业大学计算机学院, 广东 广州 510006)

摘要:该文提出一种动态剪枝的协同稀疏表示方法,通过建立2种不同的训练样本筛选策略,再融合2种策略的优点及结合TPTSR框架进行图像识别,以求获得更好的分类效果.在带噪声的人脸数据集上进行对比实验,结果表明:该方法可以在人脸受到遮挡和光照变化的影响下达到更高的识别率,并具有较强的鲁棒性.

关键词:模式识别;生物特征识别;稀疏表示;协同表示

中图分类号:TP 391 **文献标志码:**A **DOI:**10.16357/j.cnki.issn1000-5862.2020.05.04

0 引言

在过去的几十年中,图像识别技术在学术和应用领域上均取得了较大的进展.从传统的线性变换方法^[1-4](如主成分分析法和线性判别分析法)到目前流行的以人工神经网络为基础的深度学习方法^[5-7],各种方法在实际问题中得到了相应的应用.其中基于表示的方法对受噪声影响的图像识别的适应性较强,而且对计算资源和数据量要求较低,可以应用在资源受限的场景中^[8-10].然而,在实际识别任务中,常常存在一些受到光照变化、遮挡或损坏等干扰的训练样本,这些样本会直接影响基于表示方法的识别性能.因此,更准确地快速地筛选样本对提高图像识别效果有着重要的意义.

J. Wright等^[8-9]首次将基于 ℓ_1 范数的稀疏表示算法(SRC)引入人脸识别技术中,测试样本被所有训练样本所稀疏表示,然后将测试样本分类到具有最好表示能力的类别.由于其 ℓ_1 范数最小化的求解问题, SRC的计算复杂度较高.后来, Zhang Lei等^[10]提出一种基于 ℓ_2 范数的稀疏表示算法,称为协同表示(CRC),该算法大幅地降低了稀疏表示算法的计算复杂度.还有许多其他基于表示学习的方法,如 Xu Yong等^[11]提出一种通过提高原始训练样本的区分度的表示方法用于鲁棒性人脸识别; Liu Shigang等^[12]通过优化协同表示的表示系数的向量,增

加了稀疏系数的判别力,提高了分类的准确性. J. Mounsef等^[13]提出一种基于提取多类型特征的增强型稀疏表示方法,优化了模糊和遮挡的人脸图像的分类效果.

在原始的稀疏表示方法中,测试样本表示为所有训练样本的线性组合,再基于类别的表示残差进行分类.然而,一些文献的研究表明,选择合适和有竞争力的训练样本对于稀疏表示是关键的问题^[14-15].因此, Xu Yong等^[11]提出2步稀疏表示法(TPTSR), TPTSR选择 M 个训练样本作为“近邻样本”,再使用它们进行协同表示分类.由于TPTSR是基于 ℓ_2 范数的稀疏表示算法,所以它具有计算复杂度低和易于实现的优点.然而, TPTSR在真实的应用环境中往往会对参数 M 的大小敏感,容易导致识别率的降低和不稳定的分类性能.基于此,本文提出了2种灵活的策略去选择近邻样本,即对于干扰的训练样本进行剪枝,并且提出一种方法来融合2种策略的优点.实验结果表明,这种适应性算法在人脸识别中具有更高的识别率、更好的适应性和鲁棒性.

1 背景知识

给定来自 L 个类别的 n 个训练样本.第 i 个样本记为特征列向量 $\mathbf{x}_i (i = 1, 2, \dots, n)$,且第 j 个类别记为类别标签 j ,如 $j \in C_0 = \{1, 2, \dots, L\}$,其中 C_0 为所有类别的标签集合.

收稿日期:2020-03-29

基金项目:国家自然科学基金(61402118, 61673123)和广东省重点领域研发计划(2020B010166006)资助项目.

通信作者:梁路(1980-),女,江西南昌人,副教授,主要从事人工智能、协同计算、数据挖掘方面的研究. E-mail:

TPTSR 算法由 2 步组成. 在第 1 步中,测试样本 y 被所有的训练样本表示为

$$y = \sum_{i=1}^n a_i x_i, \quad (1)$$

其中 $a_i (i = 1, 2, \dots, n)$ 是相对应的系数. (1) 式可以简写成矩阵形式为

$$y = XA, \quad (2)$$

其中 $X = (x_1, x_2, \dots, x_n)$, $A = (a_1, a_2, \dots, a_n)^T$. 如果 X 是非奇异方阵, 则 $A = X^{-1}y$; 否则, $A = (X^T X + \mu I)^{-1} X^T y$, 其中 μ 是一个常量, I 是一个单位矩阵. 在 (1) 式中, $a_i x_i$ 本质上为每个训练样本 x_i 对于测试样本 y 的贡献, 可以使用样本的表示残差衡量为

$$e_s(i) = \|y - a_i x_i\|. \quad (3)$$

显然, 更小的 $e_s(i)$ 意味着对测试样本 y 有更大的表示贡献. M 个最大表示贡献的训练样本称为测试样本 y 的 M 个“近邻样本”. M 个近邻样本可记为 $\tilde{x}_i (i = 1, 2, \dots, M)$, 其类别标签集记为 C_M , 是 C_0 的一个子集, $C_M \subseteq C_0$.

在 TPTSR 算法的第 2 步中, 测试样本 y 被 M 个近邻样本表示为

$$y = \sum_{i=1}^M b_i \tilde{x}_i, \quad (4)$$

其中 $b_i (i = 1, 2, \dots, M)$ 是相对应的系数, (4) 式可以简写为

$$y = \tilde{X}B, \quad (5)$$

其中 $\tilde{X} = (\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_M)$ 和 $B = (b_1, b_2, \dots, b_M)^T$ 是系数矩阵; $B = (\tilde{X}^T \tilde{X} + \gamma I)^{-1} \tilde{X}^T y$; γ 是一个常量.

然后, 可以计算每个类别的表示贡献. 对于每一个类别 $r (r \in C_M, C_M \subseteq \{1, 2, \dots, L\})$, 其近邻样本为 $\tilde{x}_s, \dots, \tilde{x}_t$, 然后计算它们表示贡献的和为

$$g(r) = b_s \tilde{x}_s + \dots + b_t \tilde{x}_t. \quad (6)$$

因此, $g(r)$ 与 y 的残差可计算为

$$D(r) = \|y - g(r)\|^2, r \in C_M. \quad (7)$$

最后, 测试样本 y 被分类到最小残差对应的类别为

$$\text{Class_label}(y) = \arg\min_r D(r). \quad (8)$$

基于 TPTSR 的方法已经被广泛地应用于模式识别领域中, 包括人脸识别^[14,16]、掌纹识别^[17]和交通标志识别^[18]. 然而, 它的识别性能依赖于基于经验选择的参数 M , 导致不稳定的分类性能. 因此, 本文提出一种改进的 TPTSR 算法, 并且证明在人脸识别中有更好的分类性能.

2 动态剪枝的协同稀疏表示分类

下面提出了分别基于剪枝样本 (NSS) 和类别剪

枝 (NSC) 的近邻样本选择策略, 并通过融合 2 种选择策略的优点来改进 TPTSR 在人脸识别中的分类性能.

2.1 基于样本剪枝的近邻样本选择策略 (NSS)

在 TPTSR 算法的第 1 步中, 一个固定的参数 M 决定了测试样本的近邻样本的数量, 这意味着每个测试样本会被相同数量的训练样本表示, 这样做不适应于不同的测试样本. 因此, 提出更具适应性的近邻样本选择策略.

在 (3) 式中, 一个有着更小的表示残差 $e_s(i)$ 的训练样本 x_i 意味着对测试样本有更大的表示贡献. 可以通过阈值操作留下具有较小表示残差的训练样本, 并且移除其他训练样本. 例如, 若一个训练样本满足 $e_s(i) < \tau_1$, 则 x_i 就是近邻样本, 其中 τ_1 是一个阈值. 因此, 一些训练样本会被剪枝 (移除), 留下来的训练样本集记为 X_s , 相对应的样本标签集记为 C_s , 且 $C_s \subseteq C_0$.

这种剪枝操作就像小波降噪操作^[19], 在信号重构之前将小波系数阈值化, 是合理和有效的. 类似策略虽然很常见, 并且广泛应用于信号分析, 但是尚未应用于 TPTSR 方法中.

2.2 基于剪枝类别的近邻样本选择策略 (NSC)

NSS 关注的是对于每个训练样本表示能力的评定, 还有另外一种剪枝策略被称为 NSC, 关注的是对每个类别表示能力的评定. 实质上前者选择了一些“合适的”近邻样本. 然而, 由于测试样本受到不同光照和姿态变化的影响, 这些被选中的训练样本可能来自许多不同的类别, 这意味着 M 个近邻样本的对应类别大部分来自不相同的类别, 这样容易导致错误的分类. 此外, 在某些情况下, 可能会出现一个与测试样本 y 有类似的光照、阴影和遮挡的训练样本 a 被选中为近邻样本, 但实际上属于不同的类别. 很明显, a 是一个干扰的样本, 但是没有被 NSS 移除, 因为它有着较小的样本表示残差. 然而, a 可能属于一个有着较大的类别表示残差的类, 可以容易通过基于类别剪枝进行移除. 因此, NSC 可以在第 1 步通过移除一些离测试样本较远的“不好”类别, 这意味着在第 2 步留下一些“好”类别作为候选类别. 将 NSC 作为改进的 TPTSR 第 1 步, 因为 NSC 可以看作是为了更好地在下一步进行分类而对训练数据进行的预处理.

在 NSC 操作中, 测试样本被表示为 (1) 式所示, 从 (2) 式获得解, 这是 TPTSR 第 1 步中的典型步骤. 然后, 通过计算类别残差 $D(r)$, 类似 (6) ~ (7) 式,

其中 $r \in C_0$. 再通过一个阈值来对 NSC 进行类别剪枝操作:若一个类别满足 $D(r) < \tau_2$, 其中 τ_2 是一个阈值, 则这个类别作为候选类别, 其对应的训练样本被保留, 丢弃其他类别的训练样本. 将候选类别标签集记为 C_c , 且 $C_c \subseteq C_0$; 将 C_c 对应的训练样本集记为 X_c , 且 $X_c \subseteq X$.

2.3 近邻样本选择策略的融合

NSS 和 NSC 是合理的策略, 为了在 TPTSR 第 2 步中, 获得更高的识别率和稳定的分类性能, 很自然地融合 2 个策略的分类结果. 文献[20-21]证明了一些融合策略的有效性. 通过利用得分的线性加权求和的方式融合了 NSS 和 NSC 的类别表示残差. 根据 (6) 式和 (7) 式, NSS 的残差 D 可被表示为

$$D_s(w) = \|y - g_s(w)\|, w \in C_s, \quad (9)$$

其中 g_s 是 NSS 的类别表示贡献的和, C_s 是候选类别标签集, 是 $\{1, 2, \dots, L\}$ 的子集. 类似地, NSC 的残差 D 可被表示为

$$D_c(w) = \|y - g_c(w)\|, w \in C_c, \quad (10)$$

其中 g_c 是 NSC 的类别表示贡献的和, C_c 是候选类别标签集, 是 $\{1, 2, \dots, L\}$ 的子集. 本文提出的融合类别残差可被计算为

$$D_F(w) = \begin{cases} (1 - \alpha)D_s(w) + \alpha D_c(w), & w \in C_F, C_F = C_s \cap C_c, \\ D_s(w), & w \in C_s - C_F, \\ D_c(w), & w \in C_c - C_F, \end{cases} \quad (11)$$

其中 α 是权重参数. 需要强调的是, 若 w 存在于集合 $C_s \cap C_c$ 中, 计算融合类别残差, 否则使用 NSS 或 NSC 的类别残差作为融合类别残差.

较小的融合类别残差意味着更大的表示贡献, 因此, 可以将测试样本分类到有最小的融合类别残差的类中. 将提出的算法称为动态剪枝的协同稀疏表示方法 (DPCSC), 见算法 1.

算法 1: 动态剪枝的协同稀疏表示方法 (DPCSC).

输入: 归一化后的训练样本集 $X(x_1, x_2, \dots, x_n)$ 和测试样本 y .

(i) 通过 ℓ_2 范数极小化问题获得 (2) 式的解 $A = (X^T X + \mu I)^{-1} X^T y$;

(ii) 计算样本表示残差 $e(i)$ ($i = 1, 2, \dots, n$), 基于 $e_s(i) < \tau_1$, 通过 NSS 选择候选训练样本集, 并记为 X_s , 对应的标签集记为 C_s ;

(iii) 计算类别表示残差 $D(r)$ ($r \in C_0$), 基于 $D(r) < \tau_2$, 通过 NSC 选择候选类别标签集, 并记为 C_c , 对应的训练样本集 X_c ;

(iv) 对于 C_s 和 C_c , 通过 (4) ~ (6) 式, 分别计算 $g_s(w)$ 和 $g_c(w)$;

(v) 通过 (9) 式和 (10) 式分别计算 NSS 和 NSC 的类别表示残差, 并记为 $D_s(w)$ 和 $D_c(w)$;

(vi) 通过 (11) 式计算融合类别残差 $D_F(w)$.

输出: $C_{\text{lass_label}}(y) = \operatorname{argmin}_w D(w)$.

2.4 DPCSC 的分析

对于 NSS, 使用参数 τ_1 取代参数 M 来决定第 1 步中测试样本的近邻样本的数量, 这是因为在真实的环境中, 测试样本可能会受到不同程度的光照变化, 遮挡和表情的影响. 如对于图 1 中第 2 行的前 3 张人脸图像, 他们受到较小的光照的变化的影响, 只需要选择较小数量的近邻样本就能正确地分类; 而对于图 1 中第 2 行最后 4 张人脸图像, 他们受到较大的光照变化和遮挡的影响, 在第 2 步中往往需要较大数量的近邻样来正确地分类. 实际上, 一个合适的参数 τ_1 , 能够在第 1 步自适应地选择合适数量的近邻样本.

若在第 1 步中用了 NSC 策略, 则在第 2 步中, 来自同一个类的训练样本越多越利于测试样本的正确分类. 特别是在某些情况下, 它能消除个别与测试样本“很像”, 但来自于不同类别的样本的影响. 如对于受到严重光照变化的测试样本, 它可能会受到有相似的光照变化, 而来自于不同的类别的训练样本的影响. 因此, 在第 1 步中, 若丢弃的类别与测试样本的类别不同, 则 NSC 能留下与测试样本相同类别的所有训练样本. 实际上, 对于受到严重光照变化和遮挡影响的测试样本, 在第 2 步中, 最关键的不是更多相似的训练样本, 而是更多相同类别的训练样本被用来表示测试样本.



图 1 不同数据集上的图例, 第 1 到第 3 行分别展示了 ORL、Extended Yale B 和 AR 数据集的人脸图像


最后, 对从 NSS 和 NSC 分别得到的分数 (类别表示残差) 进行得分融合, DPCSC 使用加权线性融合的方式对得分进行了处理, 产生融合得分 (融合类别残差), 利用融合得分进行最终的分类. 因为这 2 种近邻样本选择策略具有较好的分类效果, 因此融合后的分类器能获得更好的分类性能是合理的. 在大多数情况下, NSC 能留下与测试样本相同类别

的所有训练样本,进而能获得更好的分类结果,因此,在融合过程中,NSC 总是有着更大的权重。

3 实验及分析

在公开的基准数据集上做了一系列的实验来评价所提出方法的性能。作为比较,对 CRC 和 TPTSR

做了相同的测试。用于测试方法的数据集,包括有 ORL、Extended Yale B 和 AR 数据集。图 1 展示了数据集的一部分图像。所有方法通过 Matlab 2016b 实现并运行了 10 次,实验结果(平均值和标准差)展示在表格上。需要强调是所有方法的参数都经过调试,以取得最好的分类结果。图 2 分别比较了不同数据集上的所有方法的识别率。



注:(a)、(b)、(c)分别展示了在 ORL、Extended Yale B 和 AR 数据集上的分类准确率曲线。

图 2 不同的分类方法在不同的数据集的分类准确率的对比

3.1 ORL 数据集的实验结果

ORL 数据集^[22]由来自 40 个个体的 400 张人脸图像组成的。每个个体包含在不同的时间、不同的光照、不同的面部表情下拍摄的。所有图像是在深色均匀的背景下拍摄的。在实验中,为了提高计算效率,数据集中的所有图像均经过归一化处理并调整至 32 × 32 像素。在图 1 中的第 1 行展示了某一个体的

所有例子。所有图像被用于测试,分别随机选择每一个个体 3、5 和 7 张图像用于训练样本,剩下的样本被用于测试样本。表 1 展示了每一种测试情况的平均准确率和对应的标准差,其中#Tr 是每一个体的训练样本数量。从表 1 可以看出,提出的近邻样本选择策略包括 NSS 和 NSC,与 CRC 和 TPTSR 相比,获得了更好的分类结果,DPCSC 获得最高的识别率。

表 1 不同方法在 ORL 数据集的分类准确率 %

#Tr	CRC	TPTSR	NSS	NSC	DPCSC
3	88.93 ± 1.93	89.11 ± 1.46	89.36 ± 1.89	89.79 ± 1.63	89.82 ± 1.66
5	93.80 ± 2.53	94.45 ± 2.09	94.55 ± 2.36	95.25 ± 1.70	95.45 ± 2.01
7	97.33 ± 1.35	97.50 ± 1.84	97.92 ± 1.43	98.58 ± 1.04	98.83 ± 0.98

3.2 Extended Yale B 数据集的实验结果

Extended Yale B 数据集^[23]包含来自 38 个个体的 2 432 张人脸正面图像,每一个体包含 64 张不同光照条件下拍摄的人脸图像。Extended Yale B 数据集的中某些图像受到了严重的光照和反射的影响。在图 1 中的第 2 行展示了 Extended Yale B 数据集的

一些代表性图像。在实验中,为了提高计算效率,图像被剪裁并调整至 32 × 32 像素。对于每一个个体,分别随机选择 10、20 和 30 张图像作为训练样本,剩下的图像作为测试样本。表 2 展示了不同方法的分类结果。可以看到 NSS 和 NSC 的分类结果好于 CRC 和 TPTSR,DPCSC 获得最好的分类性能。

表 2 不同方法在 Extended Yale B 数据集的分类准确率 %

#Tr	CRC	TPTSR	NSS	NSC	DPCSC
10	89.18 ± 0.91	89.71 ± 1.02	89.75 ± 1.06	90.04 ± 1.05	90.29 ± 0.97
20	95.83 ± 0.72	95.75 ± 0.51	95.88 ± 0.50	96.41 ± 0.59	96.61 ± 0.59
30	97.88 ± 0.67	97.79 ± 0.53	97.89 ± 0.53	98.01 ± 0.60	98.28 ± 0.51

3.3 AR 数据集的实验结果

AR 数据集^[24]由来自 126 个个体的 4 000 张彩色图像组成,每一个体的 26 张图像分别在 2 个阶段拍摄,时间间隔为 2 周。这些图像分别是在不同的面

部表情、光照变化和遮挡下拍摄的。在图 1 中的第 3 行展示了 AR 数据集的代表性图像。在实验中,所有图像进行归一化处理并调整至 40 × 50 像素。其中每一个体随机选择 5、9 和 13 张图像作为训练样本,剩

下的图像作为测试样本. 表 3 总结了实验的分类结果, 从表 3 可以看出, 在所有测试情况下, DPCSC 获得了最好的分类结果.

表 3 不同方法在 AR 数据集的分类准确率

#Tr	CRC	TPTSR	NSS	NSC	DPCSC
5	91.35 ± 0.73	92.60 ± 0.92	92.56 ± 0.93	93.02 ± 0.70	93.34 ± 0.76
9	95.32 ± 0.72	96.73 ± 0.46	96.63 ± 0.48	96.72 ± 0.52	96.96 ± 0.47
13	97.13 ± 0.51	98.40 ± 0.33	98.40 ± 0.28	98.34 ± 0.36	98.49 ± 0.27

3.4 实验结果的分析

基于上述表格所总结的实验结果, 得如下结论:

1) 在所有数据集上的实验结果表明在所有情况下, 与其他对比的方法相比, DPCSC 有更高的分类准确率. 这说明得分融合策略有效结合了近邻样本选择策略 NSS 和 NSC 的优点.

2) 与 TPTSR 相比, NSS 在 ORL 和 Extended Yale B 数据集上获得了略微更高的分类准确率, 在 AR 数据集上获得了相似的分类性能. 由此表明, 在某种程度上, 对于不同的测试样本, 不同数量的近邻样本会影响最终分类效果.

3) 值得注意的是, 与 CRC、TPTSR 和 NSS 相比, NSC 在 ORL 和 Extended Yale B 数据集上的分类效果有显著的提高. 这 2 个数据集的图像受到不同的光照变化和阴影的影响, 这说明他们受到严重光照变化和阴影的人脸图像, 需要更多与其类别相同的训练样本去表示. 这正是近邻选择样本策略 NSC 的主要特征. 即 NSC 对于受到光照变化和阴影影响的图像更具鲁棒性.

4 结论

通过筛选训练样本可以有效地提高图像识别中基于表示方法的识别性能, 本文分析了 TPTSR, 并指出其参数 M 在实际应用中的局限性. 据此, 提出 2 种近邻样本的选择策略, 包括 NSS 和 NSC, 以消除不恰当地设置参数 M 可能导致的负面影响. 此外, 为了获得更好的分类性能, 提出了 DPCSC, 融合了 NSS 和 NSC 的分类结果. 实验结果表明本文方法具有更好的分类效果和更好的鲁棒性, 特别是对于严重地受光照、阴影和遮挡影响的人脸图像. 接下来的工作是要研究解决参数设置问题, 并探索一种自动或半自动的参数设置算法.

5 参考文献

- [1] Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71-86.
- [2] Yang Jian, Zhang David D, Frangi A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [3] Belhumeur P N, Hespanha 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.
- [4] 滕少华, 卢东略, 霍颖翔, 等. 基于正交投影的降维分类方法研究 [J]. 广东工业大学学报, 2017, 34(3): 1-7.
- [5] Taigman Y, Yang Ming, Ranzato M, et al. DeepFace: closing the gap to human-level performance in face verification [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition. Columbus, OH: IEEE, 2014: 1701-1708.
- [6] Lavin A, Gray S. Fast algorithms for convolutional neural networks [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV: IEEE, 2016: 4013-4021.
- [7] 滕少华, 唐海涛, 张巍, 等. 混合 PNN 和 RBF 神经网络模型的局域降雨类型识别及雨量预测 [J]. 小型微型计算机系统, 2016, 37(11): 2571-2576.
- [8] 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.
- [9] Wright J, Ma Y, Mairal J, et al. Sparse representation for computer vision and pattern recognition [J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.
- [10] Zhang Lei, Yang Meng, Feng Xiangchu. Sparse representation or collaborative representation: which helps face recognition [C] // 2011 IEEE International Conference on Computer Vision. Barcelona: IEEE, 2011: 471-478.
- [11] Xu Yong, Zhong Zuofeng, Yang Jiayou, et al. A new discriminative sparse representation method for robust face recognition via regularization [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2233-2242.
- [12] Liu Shigang, Li Lingjun, Jin Ming, et al. Optimized coefficient vector and sparse representation-based classification

- method for face recognition [J]. IEEE Access, 2020, 8: 8668-8674.
- [13] Mounsef J, Karam L. Augmented SRC for face recognition under quality distortions [J]. IET Biometrics, 2019, 8 (6): 431-442.
- [14] Xu Yong, Zhang David, Yang Jian. A two-phase test sample sparse representation method for use with face recognition [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2011, 21(9): 1255-1262.
- [15] Xu Yong, Fang Xiaozhao. Data uncertainty in face recognition [J]. IEEE Transactions on Cybernetics, 2014, 44 (10): 1950-1961.
- [16] Wang Jie, Lan Rushi, Li Fang, et al. A new two-phase classifier for face recognition [C] // 2018 IEEE International Conference on Systems, Man, and Cybernetics, Miyazaki: IEEE, 2018: 1799-1802.
- [17] Guo Zhenhua, Wu Gang, Chen Qingwen, et al. Palmprint recognition by a two-phase test sample sparse representation [C] // 2011 International Conference on Hand-Based Biometrics, Hong Kong: IEEE, 2011 (1/2/3/4).
- [18] Deng Xiongwei, Zhang Chongyang. An improved two-phase sparse representation method for traffic sign recognition [C] // Second International Conference on Robot, Vision and Signal Processing. Kitakyushu: IEEE, 2013: 35-38.
- [19] Mallat S. A wavelet tour of signal processing: the sparse way [M]. 3rd ed. Burlington: Academic Press, 2008.
- [20] Jain A K, Ross A, Prabhakar S. An introduction to biometric recognition [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2004, 14(1): 4-20.
- [21] Xu Yong, Fei Luke, Zhang David. Combining left and right palmprint images for more accurate personal identification [J]. IEEE Transactions on Image Processing, 2015, 24 (2): 549-559.
- [22] ORL face data set [DS/OL]. <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>.
- [23] 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.
- [24] Martinez A, Benavente R. The AR face database [Z]. CVC Technical Report, 1998: 24.

The Dynamic Pruning Collaborative Sparse Classification and Its Application

ZHOU Junxing, LIANG Lu*

(College of Computer, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: The dynamic pruning collaborative sparse classification (DPCSC) method that is two flexible strategies of selecting suitable and competitive training samples for sparse representation are built separately has been proposed, and also can be combined with TPTSR framework in image recognition for achieving better performance. Extensive experiments conducted on publicly available face datasets with noise clearly show that the proposed DPCSC performs excellent accuracy under the influences of occlusion and illumination variations on the face image, and robustness for face images with illumination and occlusion.

Key words: pattern recognition; biometrics; sparse representation; collaborative representation

(责任编辑:冉小晓)