

基于快速协同表示分类和组内预测重构系数向量 l_2 范数的人脸识别算法

梅伟健, 裘国永

(陕西师范大学 计算机科学学院, 西安 710119)

摘要: 针对协同表示分类和规则化最小二乘算法 (CRC_RLS) 在人脸识别应用中识别速率缓慢的问题, 通过研究预测重构系数与人脸图片分类的关系, 提出一种基于快速协同表示分类和组内预测重构系数向量 l_2 范数算法 (FCRC_L2N)。与其他协同表示算法的不同之处在于, 改进的 FCRC_L2N 算法没有计算残差的过程, 通过引入组内预测重构系数向量的 l_2 范数直接对图片分类。标准数据集上的实验结果显示了该算法的高效性。

关键词: 协同表示; 重构系数; l_2 范数

中图分类号: TP315.69 doi: 10.19734/j.issn.1001-3695.2018.11.0926

Face recognition algorithm based on FAST collaborative representation classification with intra-group prediction reconstruction coefficient l_2 norm

Mei Weijian, Qiu Guoyong

(School of Computer Science, Shaanxi Normal University, Xi'an 710119, China)

Abstract: Aiming at the problem that the collaborative representation classification with regularized least squares algorithm (CRC_RLS) recognition execution is slow in face recognition applications, this paper developed an algorithm based on fast collaborative representation classification with intra-group prediction reconstruction coefficient l_2 norm (FCRC_L2N) by studying the relationship between predictive reconstruction coefficients and face image classification. The difference from other cooperative representation algorithms is that the FCRC_L2N algorithm does not have a process of calculating the residual, and directly classifies the picture by introducing the l_2 norm of the intra-group prediction reconstruction coefficient vector. The experimental results on the standard data set show the efficiency of the algorithm.

Key words: collaborative representation; reconstruction coefficient; l_2 -norm

0 引言

人脸识别是基于人的脸部特征信息进行身份识别的一种生物识别技术。人脸识别算法的性能在很大程度上决定了人脸识别系统的性能, 因此人脸识别算法研究在理论和实际应用中具有重要的研究价值。

人脸识别算法的性能主要体现在识别精度和识别速度两个方面。在识别精度方面, Wright 等人^[1]提出了经典的基于稀疏表示分类 (sparse representation classification, SRC) 的人脸识别算法, 因其对光照、遮挡等问题良好的鲁棒性, 真正意义上提高了人脸识别精度, 从而受到学者大量关注^[3-17]。随后大量基于 SRC 的改进算法在高水平信息平台发表。但 L_1 范数最小化问题导致该算法识别速度缓慢。在识别速度方面, Zhang 等人^[2]提出了经典的 CRC_RLS 人脸识别算法, 该算法是一种优化的 SRC 算法。其核心贡献在于指出协同表示对分类结果具有重要意义, 用 l_2 范数取代 L_1 范数求解最优化问题, 进而提高算法识别速度。随后大量基于协同表示分类 (collaborative representation classification, CRC) 的扩展算法^[18-26]在高水平学术期刊发表。但当图片特征维数较高时, 该算法识别速度仍然缓慢。随着人脸识别系统中训练样本数量和图片特征维数的增加, 以及人们对高效执行效率的迫切需要, 识别速度变得越来越重要。

已发表的有关 CRC 算法识别方法各异, 但算法结构高度一致, 可以概括为重构编码、计算残差、分类识别三个过程。

算法框架固定导致算法改进的范围具有一定的局限性, 识别速度也很难有大的突破。针对这一问题, 本文希望从结构上改变算法。首先本文对计算残差这一过程的必要性和合理性提出质疑。原算法计算残差的原因是希望找到与待识别样本差异最小的一组人脸图片, 从而达到分类的目的。但本文认为直接从重构编码的结果预测重构系数向量中提取分类信息也能达到分类的目的。计算残差是对前者的承接与扩展, 剔除计算残差的过程, 不会丢失分类信息。后文实验可以验证该想法的正确性, 所以对于分类该过程并非一定需要。计算残差的方法复杂, 算法执行过程中该过程执行时间占整个实验执行时间的比重大, 并且涉及到重复使用字典矩阵的问题, 所以算法中该过程的设计并不合理, 需要提出一种更合理与客观的算法结构, 进而改进算法。

对此, 本文在 CRC_RLS 算法的基础上, 依次提出基于快速协同表示分类和预测重构系数向量中最大值 (fast collaborative representation classification with maximum coefficient, FCRC_MC) 人脸识别算法、基于组内预测重构系数向量 l_2 范数的 FCRC_L2N 人脸识别算法。本文的贡献点主要包括: a) 提出一种新的基于重构编码和分类识别的算法结构, 没有计算残差的过程, 算法复杂度大规模降低, 进而超大幅度地提高了识别速度; b) 挖掘出预测重构系数向量中隐含的分类信息, 直接通过预测重构系数向量对待测样本进行分类, 分类结果与残差无依赖关系; c) 综合考虑每组预测重构系数向量中系数间的关系, 通过引入组内预测重构系数

收稿日期: 2018-11-27; 修回日期: 2019-02-28

作者简介: 梅伟健 (1990-), 男, 硕士研究生, 主要研究方向为计算机视觉 (1904355229@qq.com); 裘国永 (1964-), 男, 副教授, 博士, 主要研究方向为智能信息处理。

向量的 l_2 范数, 得到高性能的算法模型。

1 协同表示分类算法

本章主要介绍基于协同表示分类的经典算法—CRC_RLS 算法。首先对 CRC_RLS 算法人脸识别问题进行形式化定义和描述; 然后回顾了该算法的核心理论, 包括预测重构系数向量的求解原理和计算残差的过程及几何解释; 最后对该算法进行客观评价。

1.1 经典 CRC_RLS 人脸识别算法

标准的基于协同表示分类 (CRC_RLS) 的人脸识别问题流程如下:

a) 构建训练样本字典矩阵 A 和测试样本 y 。

假设训练用的人脸库中有 k 个人, 每人 b 张人脸图片。对每张图片进行特征提取。常见的特征提取的方法有基于集合特征法、基于模型匹配法、基于图片像素点数值法、基于主成分分析法^[27]、基于支持向量机法^[28]、基于子空间分析法^[29]、基于马尔可夫链模型法等。为了简便, 本文选用图片像素点数值作为每张人脸图片的特征。假设每个特征有 m 维, 则可以将训练用的人脸库中的 n (令 $n=k*b$) 个特征表示为一个字典矩阵 $A(A \in \mathbb{R}^{m*n})$, 矩阵 A 中的每列向量表示一张人脸图片。第 i 个人的 b 张人脸图片可以表示为矩阵 $A_i = [a_{i1} a_{i2} a_{i3} \dots a_{ib}]$, $i=1, 2, 3, \dots, k$ 。全体训练样本包含 k 个小组, 可以表示为矩阵 $A = [A_1 A_2 A_3 \dots A_k]$ 。

b) 计算预测重构系数向量 $\hat{\rho}$ 。

基于协同表示分类的人脸识别问题可以表示为

$$\hat{\rho} = \operatorname{argmin}\{y - A\rho_2^2 + \lambda\rho_2^2\} \quad (1)$$

c) 计算每个组的残差。

$$r_i = y - A_i \hat{\rho}_2 \quad (2)$$

d) 计算待识别样本 y 的预测类别标号。

$$\operatorname{Identity}(y) = \operatorname{argmin}(r_i) \quad (3)$$

CRC_RLS 算法的步骤如算法 1 所示。

算法 1 CRC_RLS 算法

- 1 Normalize the columns of A to have unit l_2 -norm.
- 2 Code y over A by $\hat{\rho} = Py$, where $P = (A^T A + \lambda I)^{-1} A^T$
- 3 Compute the regularized residuals, $r_i = y - A_i \hat{\rho}_2 / \hat{\rho}_2$
- 4 Output the identity of y as $\operatorname{Index}(y) = \operatorname{argmin}(r_i)$

1.2 预测重构系数向量 $\hat{\rho}$

预测重构系数向量是人脸识别的关键, 求解原理如下: 令

$$f(\rho, \lambda) = y - A\rho_2^2 + \lambda\rho_2^2 \quad (4)$$

关于 ρ 求偏导得

$$\frac{\partial f(\rho, \lambda)}{\partial \rho} = \frac{\partial \{(y - A\rho)^T (y - A\rho) + \lambda\rho^T \rho\}}{\partial \rho} = (A^T A + \lambda I)\rho + 2\lambda\rho - 2A^T y \quad (5)$$

根据拉格朗日乘子法, 令式 (2) 等于 0, 得到

$$A^T A + \lambda I \rho + 2\lambda\rho - 2A^T y = 0 \quad (6)$$

化简可得

$$\rho = (A^T A + \lambda I)^{-1} A^T y \quad (7)$$

其中: $I \in \mathbb{R}^{m*n}$ 为单位矩阵。

1.3 计算残差的过程与几何解释

在图 1 中, α 表示字典矩阵 A 的超平面; \hat{y} 表示待识别图片 y 在超平面 α 上的投影; x_i 表示第 i 组内所有训练样本的协同表示, \bar{x}_i 表示除第 i 组外所有训练样本的协同表示, r_i 表示待识别图片 y 与 x_i 的误差。

包括 CRC_RLS 算法在内的基于协同表示分类的系列算法均含有计算残差的过程, 通过求解所有组残差中的最小值对识别样本进行分类。该过程涉及到表达式 $r_i = y - A_i \hat{\rho}_2^2$ 。该表

达式可以转换为如下形式:

$$r_i = \|y - \hat{y}\|_2^2 + \|\hat{y} - A_i \hat{\rho}_2\|_2^2 \quad (8)$$

显然, $r_i^* = \|\hat{y} - A_i \hat{\rho}_2\|_2^2$ 对最终的分类起到了作用, 因为对于所有组, $\|y - \hat{y}\|_2^2$ 是常量。易得

$$\frac{\hat{y}_2}{\sin(\chi_i, \bar{x}_i)} = \frac{\hat{y} - A_i \hat{\rho}_2}{\sin(\hat{y}, \chi_i)} \quad (9)$$

其中: (χ_i, \bar{x}_i) 表示 χ_i 与 \bar{x}_i 的夹角; (\hat{y}, χ_i) 表示 \hat{y} 与 χ_i 的夹角。最终变量 r_i^* 可以表示为

$$r_i^* = \frac{\sin^2(\hat{y}, \chi_i) \hat{y}_2^2}{\sin^2(\chi_i, \bar{x}_i)} \quad (10)$$

式 (10) 表明, 要得到变量 r_i^* 的最小值, \hat{y} 与 χ_i 的夹角需要尽可能小, χ_i 与 \bar{x}_i 的夹角需要尽可能大。上述两个约束条件使分类结果有效鲁棒。当类别的数量过多时基于 r_i 的分类结果变得不稳定, CRC_RLS 算法通过添加基于 l_2 范数的预测重构系数向量的正则项来解决该问题。

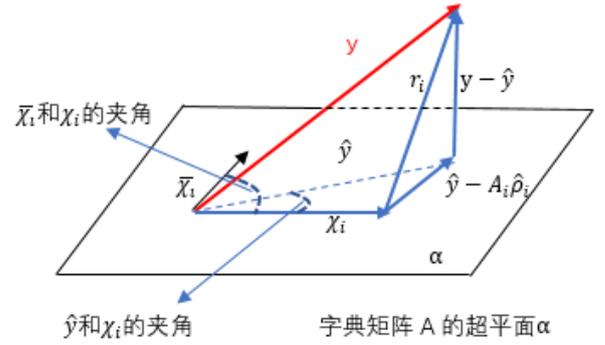


图 1 协同表示的几何解释

Fig. 1 Geometric Interpretation of Cooperative Representation

1.4 CRC_RLS 算法的评价

CRC_RLS 算法继承了 SRC 算法对光照、遮挡等噪声具有强鲁棒性的优点, 但该算法以及其他基于协同表示的系列算法仍具有诸多不足: a) 这些算法结构高度一致, 均包含重构编码、计算残差、分类识别的过程, 算法结构固定致使算法设计范围具有局限性, 不利于算法改进; b) 这些算法均需二次用到字典矩阵, 重复使用字典矩阵导致算法结构冗余, 并且理论上第二次用到相同字典矩阵对最终的分类结果贡献率极低; c) 该系列算法中计算残差的过程较复杂, 并且均包含字典矩阵各组列向量与对应预测重构系数向量线性组合的过程, 计算残差的执行时间占整个实验执行时间的比重大, 计算和存储开销均较大。然而上述三点不足最终导致了 CRC_RLS 算法识别速度缓慢的问题。

2 本文算法

为了改进 1.4 节中 CRC_RLS 算法存在的不足, 解决 CRC_RLS 算法识别速度缓慢的问题, 本文提出了基于快速协同表示分类和预测重构系数向量中最大值人脸识别算法和基于组内预测重构系数向量 l_2 范数的 FCRC_L2N 人脸识别算法。本章将首先描述发现算法改进依据的过程, 然后介绍第一种算法重点改进的部分以及进一步改进算法的过程, 最后介绍了第二种算法重点改进的部分。

2.1 改进算法的依据

首先, 本文查看了 AR 标准数据集中的测试样本图片, 并计算出每张测试样本图片对应的预测重构系数向量。为了方便观察, 本文将每张测试样本的预测重构系数向量可视化, 部分测试样本对应的预测重构系数向量如图 2 所示。图 2 中展示了 3 个测试样本对应的预测重构系数向量, 每个向量包

含 700 个元素, 元素的横坐标表示训练集中训练样本的序号, 每 7 张训练样本图片为一个小组, 一共 100 个小组, 共 700 张训练样本图片。接着, 本文通过观察发现测试样本图片中, 大部分测试样本图片对应的预测重构系数向量具有以下特点: a) 每张图片对应的预测重构系数向量中大部分训练样本序号对应的系数值范围比较集中; b) 每张图片对应的预测重构系数向量中极个别训练样本序号对应的系数值严重偏离均值。然后, 本文又着重研究了每张测试样本图片的预测重构系数向量中的最大值与测试样本图片的类别标号之间的关系, 发

现大部分测试样本图片的预测重构系数向量的最大值所对应序号的组号与该图片的类别标号相同。例如, 某测试样本图片的预测重构系数向量中的最大值 318.267 对应的第 29 号训练样本图片位于训练样本集的第 5 组, 而该待测样本图片的类别标号同样为 5, 该现象说明预测重构系数向量中隐含着丰富的分类识别信息, 预测重构系数向量中的最大值与待测图片的类别标号存在关联。基于以上观察与分析, 本文首先提出了直接基于预测重构系数向量中最大值的 FCRC_MC 算法。

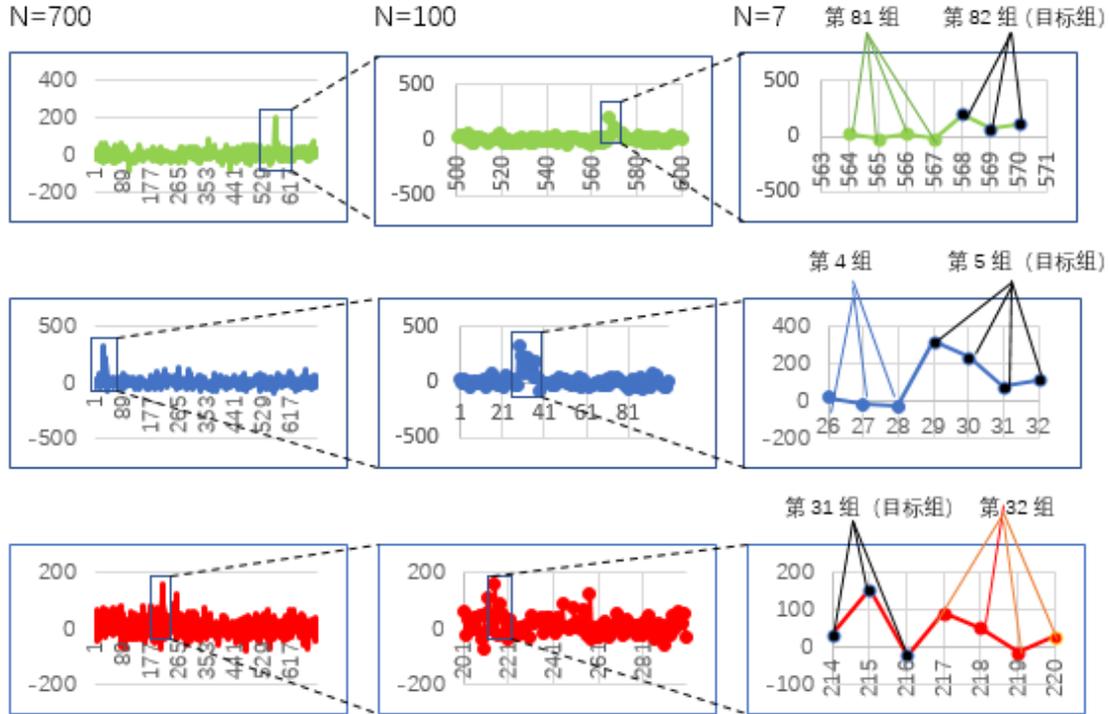


图 2 部分测试样本预测重构系数向量 (样本的类别标号依次为 82、5、31)

Fig. 2 Partial test sample prediction reconstruction coefficient (category label of sample is 82, 5, 31 in order)

2.2 基于预测重构系数向量中最大值的 FCRC_MC 算法

FCRC_MC 算法在 CRC_RLS 算法的基础上作出如下改进:

a) 更改算法结构。剔除 CRC_RLS 算法中计算残差的过程。原算法计算残差的原因是找到训练集中与待识别样本差异最小的一组人脸照片, 从而达到分类的目的。本文认为直接从重构编码的结果预测重构系数向量中提取分类信息也能达到分类的目的。计算残差是对前者的承接与扩展, 剔除计算残差的过程, 不会丢失分类信息。后文实验也验证了这样做的合理性。所以计算残差这一过程对于样本分类并非一定需要。而计算残差的方法复杂, 算法执行过程中该过程执行时间占整个实验执行时间的比重大, 并且涉及到重复使用字典矩阵的问题, 所以算法中该过程的设计并不合理。计算残差过程的移除会极大地降低算法的时间复杂度, 简化算法结构, 算法运行时间将大幅度降低。改进前后算法结构对比如图 3 所示。图中 A 表示字典矩阵; y 表示待识别图片; F 表示计算预测重构系数向量的模型; K 表示计算残差的模型; H 表示改进前的分类准则模型; G 表示改进后的分类准则模型; R 表示识别结果; 灰色框图表示该过程已删除。

b) 更改分类准则。在发现预测重构系数向量中的最大值与待测图片类别标号存在关联后, 本文更改了算法分类依据。CRC_RLS 算法的分类依据为所有组残差计算结果中的最小值, FCRC_MC 算法的分类依据为预测重构系数向量中的最大值即最大值。综上所述, FCRC_PV 算法的步骤如算法 2 所示。

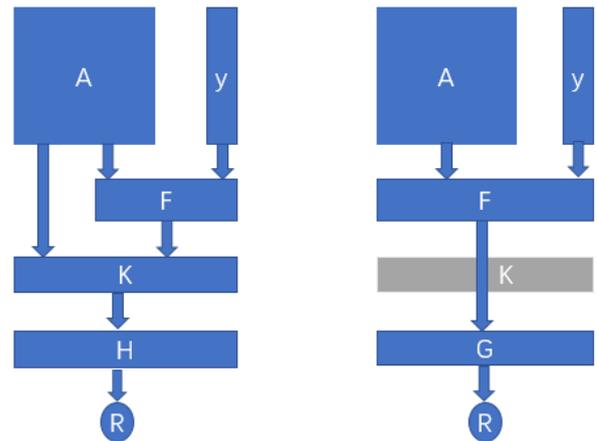


图 3 改进前后算法结构对比

Fig. 3 Comparisons of algorithm structures before and after modification

算法 2 FCRC_MC 算法

- 1 Normalize the columns of A to have unit l_2 -norm.
- 2 Code y over A by $\hat{\rho} = Py$, where $P = (A^T A + \lambda I)^{-1} A^T$
- 3 Computer maximum coefficient ω in $\hat{\rho}$, $\omega = \underset{i,j}{\operatorname{argmax}} \{\hat{\rho}_{i,j}\}$
- 4 Output the identity of y as $\operatorname{Index}(y) = i$

2.3 基于组内预测重构系数向量 l_2 范数的 FCRC_L2N 算法

在 2.1 节的讨论中, 本文假定每个人只有一张图片, 即数据集中每组图片中只有一张图片, 那么预测重构系数向量 $\hat{\rho}_{i,j}$ 不仅能代表第 i 组的第 j 张图片, 而且能代表整个第 i 组。然而通常数据集中每组至少有两张图片。如果本文用 $\max(\hat{\rho}_{i,j})$ 代表第 i 组, 最终的分类结果不够稳定。因为每组图片对应若干系数, 无论其中任何一个系数有多大, 该系数也无法取代组内剩余系数代表第 i 组。当某一张图片受到不可预测噪声干扰时, 该图片所对应的系数也可能很大, 但某一组图片同时受到不可预测噪声干扰的概率却很小, 所以每个组与待测样本的关系应该由该组对应的若干系数协同表示。在 FCRC_MC 算法的基础上, 基于以上分析, 本文提出了 FCRC_L2N 算法。该算法作出了更深入的改进:

a) 引入组内预测重构系数向量 l_2 范数 $\hat{\rho}_2$ 。由表达式 $\hat{\rho}=(A^T A+\lambda I)^{-1} A^T y$ 可知, 预测重构系数向量 $\hat{\rho}$ 是由字典矩阵 A 与待测图片 y 协同作用的结果。 $\hat{\rho}_i$ 是 $\hat{\rho}$ 的第 i 个分量, 对应于字典矩阵 A 中的第 i 组图片; $\hat{\rho}_2$ 是第 i 组图片所对应系数综合作用的结果, 一定程度上反映了该组图片与待测样本的关联程度, 而这种关联程度与最终的识别结果存在一定的映射关系, 所以 $\hat{\rho}_2$ 含有重要的分类识别信息。本文抽取标准数据集中的测试样本图片, 计算每张图片所有组的 $\hat{\rho}_2$, 将部分图片所有组的 $\hat{\rho}_2$ 可视化后如图 4 所示。

b) 将每张图片所有组的 $\hat{\rho}_2$ 中的最大值作为分类依据。将待测样本与目标组样本进行关联, 从而有效分类是分类识别算法的一个最基本的思路。本文通过观察每个待测样本预测重构系数向量的所有组内系数的 l_2 范数和待测样本的类别标号后发现绝大多数待测样本的组内系数的 l_2 范数的最大值所对应的训练样本组序号与待测样本的类别标号相同。例如, 某待测样本组内预测重构系数向量的 l_2 范数的最大值 275.379 所对应的组序号为 82, 而该待测图片的类别标号同样为 82, 即待测图片对应的 $\max\{\hat{\rho}_2\}$ 能较好地将该图片与目标组图片进行匹配。基于这种观察, FCRC_L2N 算法将待测图片所有组 $\hat{\rho}_2$ 中的最大值作为待测图片分类识别的依据。综上所述, FCRC_L2N 算法的步骤如算法 3 所示。

算法 3 FCRC_L2N 算法

1. Normalize the columns of A to have unit l_2 -norm.
2. Code y over A by $\hat{\rho}=P y$, where $P=(A^T A+\lambda I)^{-1} A^T$
3. Computer $\hat{\rho}_2$ of group in $\hat{\rho}$, $\tau=\operatorname{argmax}_i\{\hat{\rho}_2\}$
- 4 Output the identity of y as $\operatorname{Index}(y)=i$

事实上 FCRC_MC 算法是一种特殊的 FCRC_L2N 算法, 当数据集中每组只有一张照片时, FCRC_L2N 算法自动退化成某种形式的 FCRC_MC 算法。

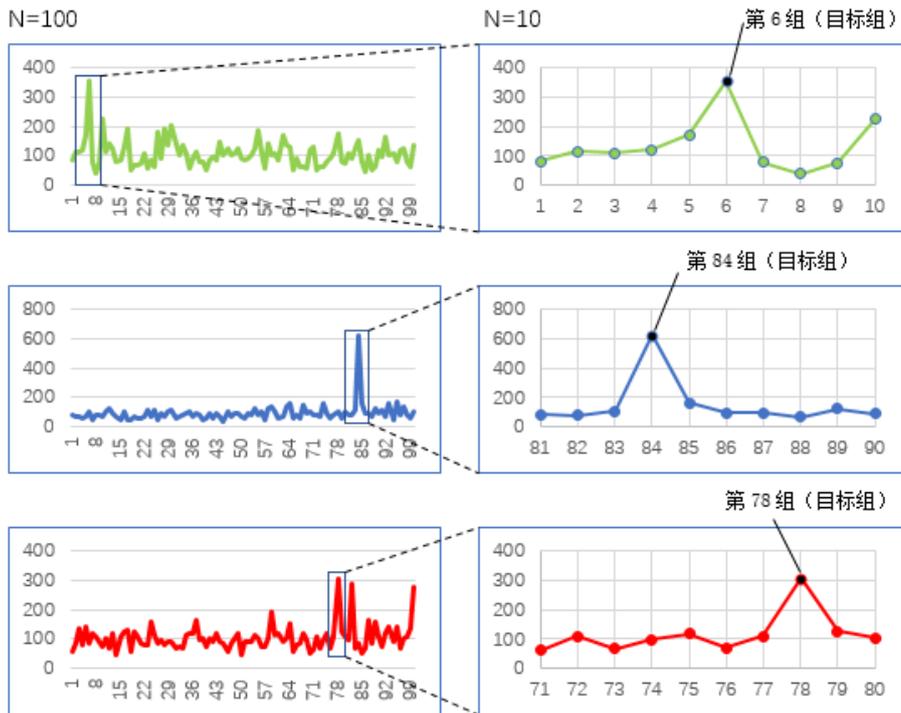


图 4 部分测试样本预测重构系数向量组内系数向量 l_2 范数(样本类别标号依次为 6、84、78)

Fig. 4 l_2 norm of intra-group coefficients of prediction reconstructed coefficients for some test samples (category label of sample is 6, 82, 78 in order)

3 实验

本章主要展示了 CRC_RLS、FCRC_MC 和 FCRC_L2N 共 3 种算法的实验结果。本文首先介绍了实验选择的数据集和实验环境, 然后设计了两组实验从不同角度对比各算法的性能情况。

3.1 数据集

为了避免实验的偏向性, 本文采用 AR、Extended Yale B、Yale 和 ORL 四个独立的数据集进行算法验证。其中 AR 数据集中包含 100 组人脸图片, 每组 14 张图片, 每张图片特征维 2 580; Extended Yale B 数据集包含 15 组人脸图片, 每组 32

张图片, 每张图片特征维数 8 084; Yale 数据集包含 15 组人脸图片, 每组 11 张图片, 每张图片特征维数 10 000; ORL 数据集包含 40 组人脸图片, 每张图片特征维数 10 304。

3.2 实验环境

Windows 10 中文版, 64 位操作系统; 基于 x64 的 Intel® Core™ i5-6600CPU@3.30 GHZ 的处理器; 8.00 GB 内存 (RAM); Anaconda3(64-bit), Python3.5。

3.3 实验结果与分析

3.3.1 实验 1 运行时间测试

各算法实验结果如表 1~4 所示。表 1 展示了各算法在 AR 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC

算法平均运行时间由原算法的 2 851 ms 缩减至 59 ms, 下降了 2 792 ms, 平均运行速度提高了 47.322 倍; 本文提出的 FCRC_L2N 算法平均运行时间由原算法的 2 851 ms 缩减至 59 ms, 下降了 2 792 ms, 平均运行速度提高了 47.322 倍。图 5 (a) 直观地展示了在 AR 数据集中本文算法与原算法在运行时间上的差异。表 2 展示了各算法在 Extended Yale B 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法平均运行时间由原算法的 5 977 ms 缩减至 55 ms, 下降了 5 922 ms, 平均运行速度提高了 107.67 倍; 本文提出的 FCRC_L2N 算法平均运行时间由原算法的 5 977 ms 缩减至 38 ms, 下降了 5 939 ms, 平均运行速度提高了 156.28 倍。图 5 (b) 直观地展示了在 Extended Yale B 数据集中本文算法与原算法在运行时间上的差异。表 3 展示了各算法在 Yale 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法平均运行时间由原算法的 8 041 ms 缩减至 10 ms, 下降了 8 031 ms, 平均

运行速度提高了 803.1 倍; 本文提出的 FCRC_L2N 算法平均运行时间由原算法的 8 041 ms 缩减至 10 ms, 下降了 8 031 ms, 平均运行速度提高了 803.1 倍。图 5 (c) 直观地展示了在 Yale 数据集中本文算法与原算法在运行时间上的差异。表 4 展示了各算法在 ORL 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法平均运行时间由原算法的 29 296 ms 缩减至 235 ms, 下降了 29 061 ms, 平均运行速度提高了 123.66 倍; 本文提出的 FCRC_L2N 算法平均运行时间由原算法的 29 296 ms 缩减至 368 ms, 下降了 28 928 ms, 平均运行速度提高了 78.61 倍。图 5 (d) 直观地展示了在 AR 数据集中本文算法与原算法在运行时间上的差异。不难发现, 本文提出的算法在运行速度上有了超大幅度地改善, 主要是由于本文在基于重构编码和分类识别的结构下设计出 FCRC_MC 和 FCRC_L2N 算法, 两种算法中均没有计算残差这一时间复杂度较高的过程, 并且两种算法中分类准则的设计简练。

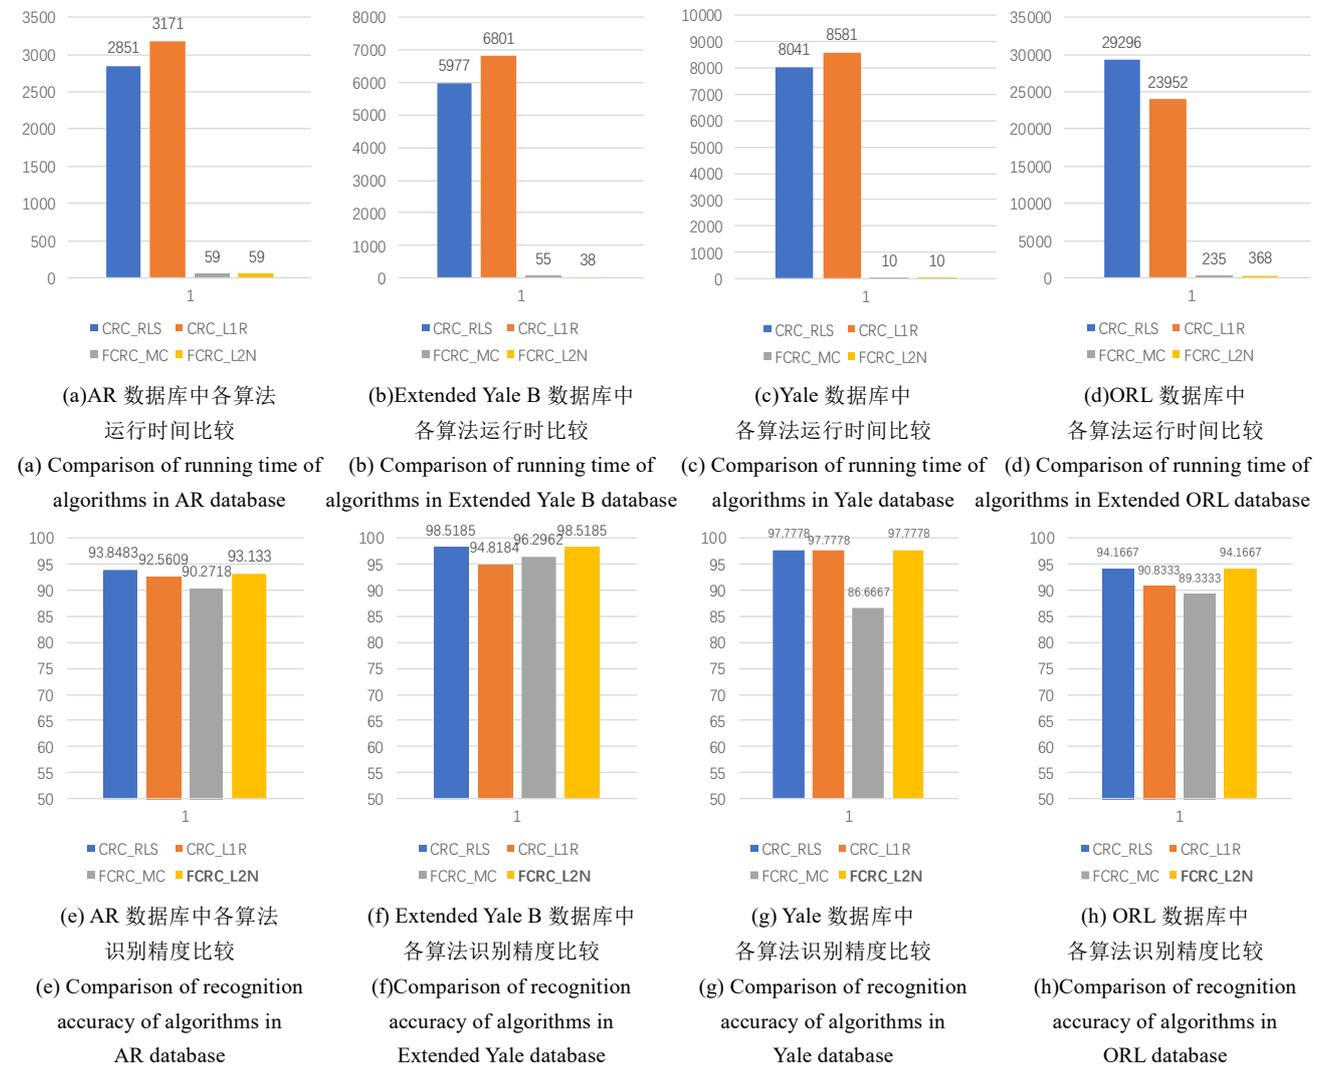


图 5 各算法在不同数据库中性能情况比较

Fig. 5 Performance comparison of algorithms in different databases

表 1 AR 数据库中各算法识别时间比较

Table 4 Comparison of algorithm recognition time in AR database

方式	关键参数比较	辅助参数比较							
		最短时间	最长时间	平均时间	提速幅度	标准方差	极差	中值	众数
经典算法	CRC_RLS	2626	4101	2851	-	167.5	1475	2778	2726
	CRC_L1R	3014	9998	3171		779.2	6826	3663	3420
改进算法	FCRC_MC	52	78	59	+47.322	3.324	25.93	58.84	57.85
	FCRC_L2N	53	81	59	+47.322	3.352	27.93	58.84	58.84

表 2 Extended Yale B 数据库中各算法识别时间比较
Table 5 Comparison of algorithm recognition time in Extended Yale B database

方式		关键参数比较				辅助参数比较			
		最短时间	最长时间	平均时间	提速幅度	标准方差	极差	中值	众数
经典算法	CRC_RLS	5806	9405	5977	-	329.6	3599	5916	5917
	CRC_L1R	6391	8936	6801		378.7	2544	6685	6523
改进算法	FCRC_MC	39	79	55	+107.67	7.573	40.01	49.98	49.97
	FCRC_L2N	29	49	38	+156.28	4.726	19.99	39.98	39.98

表 3 Yale 数据库中各算法识别时间比较
Table 6 Comparison of algorithm recognition time in Yale database

方式		关键参数比较				辅助参数比较			
		最短时间	最长时间	平均时间	提速幅度	标准方差	极差	中值	众数
经典算法	CRC_RLS	7987	8292	8041	-	62.39	304.5	8027	8020
	CRC_L1R	8525	8855	8581	-	62.2	330.1	8559	8557
改进算法	FCRC_MC	9	14	10	+803.1	1.274	4.99	9.973	9.974
	FCRC_L2N	9	15	10	+803.1	1.05	5.985	9.974	9.974

表 4 ORL 数据库中各算法识别时间比较
Table 7 Comparison of algorithm recognition time in ORL database

方式		关键参数比较				辅助参数比较			
		最短时间	最长时间	平均时间	提速幅度	标准方差	极差	中值	众数
经典算法	CRC_RLS	28592	32214	29296	-	405.7	1302	29830	29880
	CRC_L1R	22640	27576	23952	-	1208	4935	23450	22850
改进算法	FCRC_MC	126	1397	235	+123.66	215	1271	161	127
	FCRC_L2N	145	2622	368	+78.61	304.4	1401	189	129

3.3.2 实验 2 识别精度测试

各算法实验结果如表 5~8 所示。表 5 展示了不同参数下各算法在 AR 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法的最高识别精度为 90.271 8%, 与原算法只相差 0.035 765; 本文提出的 FCRC_L2N 算法的最高识别精度为 93.133 0%, 与原算法仅相差 0.007 153。图 5 (e) 展示了在 AR 数据集中本文算法与 CRC_RLS 算法在识别精度上的差异。表 6 展示了不同参数下各算法在 Extended Yale B 数据集中的实验结果。可以看出, 在不同参数下相同算法的识别精度不相同, 本文提出的 FCRC_MC 算法的最高识别精度为 96.296 2%, 与原算法仅相差 0.022 223; 而本文提出的 FCRC_L2N 算法的最高识别精度为 98.518 5%, 与 CRC_RLS 算法的识别精度相同。图 5 (f) 展示了在 Extended Yale B 数据集中本文算法与 CRC_RLS 算法在识别精度上的差异。表 7 展示了不同参数下各算法在 Yale 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法的最高识别精度为 86.666 7%, 与原算法只相差 0.111 11; 本文提出的 FCRC_L2N 算法的最高识别精度为 97.777 8%, 与原算法相同。图 5 (g) 展示了在 Yale 数据集中本文算法与 CRC_RLS 算法在识别精

度上的差异。表 8 展示了不同参数下各算法在 ORL 数据集中的实验结果。可以看出, 本文提出的 FCRC_MC 算法的最高识别精度为 89.333 3%, 与原算法只相差 0.048 334; 本文提出的 FCRC_L2N 算法的最高识别精度为 94.166 7%, 与原算法相同。图 5 (h) 展示了在 ORL 数据集中本文算法与 CRC_RLS 算法在识别精度上的差异。不难发现, 本文提出的算法同样具有较高的识别精度, 这表明了 FCRC_MC 算法和 FCRC_L2N 算法的有效性, 主要原因是本文提出的两种算法根据其各自的分类准则能很好地将待识别样本的类别标号与目标组的组号进行关联匹配; 本文在提出 FCRC_MC 算法后, 通过引入组内预测重构系数向量的 l_2 范数进一步改进算法提出 FCRC_L2N 算法, 实验结果显示 FCRC_L2N 算法相比于 FCRC_MC 算法, 在 AR、Extended Yale B、Yale 和 ORL 数据集中的识别精度分别提高了 2.861 2%、2.222 3%、11.111 1%、4.833 4%, 这表明本文进一步改进过程的有效性。主要原因是基于组内预测重构系数向量的 l_2 范数的分类准则相比基于预测重构系数向量最大值的分类准则, 能使待识别样本的类别标号与目标组的组号产生更强的关联。

表 5 AR 数据库中各算法在不同参数下识别率比较
Table 8 Comparison of recognition rates of different algorithms under different parameters in AR database

	λ	0.001	0.003	0.009	0.01	0.03	0.06	0.08	0.1	0.11	0.12	0.15	0.2
		经典算法	CRC_RLS	78.3977	85.6938	90.2718	90.4148	92.5608	92.9899	93.5622	93.5622	93.7052	93.8483
	CRC_L1R	72.103	80.9728	88.6981	88.4812	90.9871	92.2747	92.5609	92.7039	92.3039	92.99	92.7039	92.1316
改进算法	FCRC_MC	78.8268	83.5479	86.9814	87.1244	88.9842	89.6995	90.2718	90.1287	90.1287	90.1287	90.1287	90.4148
	FCRC_L2N	72.8183	81.5450	88.5550	89.1273	91.2732	92.2746	92.5608	92.7038	92.7038	93.1330	92.7038	92.1316

表 6 Extended Yale B 数据库中各算法在不同参数下识别率的比较

Table 9 Comparison of recognition rates of different algorithms under different parameters in Extended Yale B database

λ		0.001	0.003	0.009	0.01	0.03	0.06	0.08	0.1	0.11	0.12	0.15	0.2
经典算法	CRC_RLS	90.3703	93.3333	98.5185	98.5185	98.5185	96.2962	95.5555	94.8148	94.8148	94.8148	94.8148	92.5925
	CRC_L1R	86.6667	91.1111	94.8148	94.8184	97.7778	98.5158	98.5158	98.5158	98.5158	98.5158	97.037	95.5556
改进算法	FCRC_MC	91.9518	94.074	96.2962	96.2962	94.074	93.3333	91.8518	91.1111	91.1111	91.1111	88.8888	87.4074
	FCRC_L2N	92.5925	96.2962	98.5185	98.5185	98.5185	95.5555	95.5555	94.8148	94.8148	94.8148	94.074	92.5925

表 7 Yale 数据库中各算法在不同参数下识别率的比较

Table 10 Comparison of recognition rates of different algorithms under different parameters in Yale database

λ		0.01	0.03	0.05	0.06	0.1	0.3	0.6	0.9	1.1	1.5	1.9
经典算法	CRC_RLS	95.5556	97.7778	97.7778	95.5556	95.5556	95.5556	91.1111	88.8889	84.4444	82.2222	82.2222
	CRC_L1R	97.7778	97.7778	97.7778	97.7778	97.7778	95.5556	93.3333	88.8889	84.4444	82.2222	82.2222
改进算法	FCRC_MC	80	80	84.4444	86.6667	86.6667	86.6667	82.2222	82.2222	77.7778	75.5556	73.3333
	FCRC_L2N	93.7778	97.7778	97.7778	95.5556	95.5556	95.5556	91.1111	88.8889	84.4444	82.2222	82.2222

表 8 ORL 数据库中各算法在不同参数下识别率的比较

Table 11 Comparison of recognition rates of different algorithms under different parameters in ORL database

λ		0.01	0.1	0.3	0.6	0.7	0.9	1.1	1.5	1.9
经典算法	CRC_RLS	87.5	92.5	92.5	94.1667	93.3333	91.6667	91.6667	90	87.5
	CRC_L1R	90.8333	89.1667	83.3333	80.8333	80	78.3333	78.3333	75.8333	75
改进算法	FCRC_MC	82.5	88.3333	89.3333	89.1667	88.333	86.6667	86.6667	86.6667	86.6667
	FCRC_L2N	87.5	92.5	92.5	94.1667	93.3333	91.6667	91.6667	90	87.5

4 结束语

为了解决 CRC_RLS 算法识别速度缓慢的问题, 本文依次提出了基于预测重构系数向量最大值的 FCRC_MC 算法、基于组内预测重构系数向量 l_2 范数的 FCRC_L2N 算法。与原算法相比, 本文首先提出了基于重构编码和分类识别的算法结构, 挖掘预测重构系数向量隐含的分类信息, 引入基于预测重构系数向量中最大值的分类准则, 进而超大幅度地提升算法识别速度。最后, 充分考虑组内各系数间的关系, 引入组内预测重构系数向量 l_2 范数, 进一步提高了算法识别精度。综上, 本文最终提出的 FCRC_L2N 算法能较好地解决 CRC_RLS 算法识别速度缓慢的问题, 同时兼顾算法识别精度。FCRC_L2N 算法仍然有不足之处, 如其中一个数据集中算法精度略有下降, 将在今后的工作中进一步探索。

参考文献:

[1] Wright J, Yang A Y, Sastry S S, *et al.* Robust face recognition via sparse representation [J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2009, 31 (2): 210-227.

[2] Zhang Lei, Meng Yang, Feng Xiangchu. Sparse representation or collaborative representation: which helps face recognition? [C]// Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE Press, 2012: 471-478.

[3] Ortiz E G, Becker B C. Face recognition for Web-scale datasets [J]. Computer Vision and Image Understanding, 2014, 118: 153-170.

[4] Yang Meng, Zhang Lei, Yang Jian, *et al.* Robust sparse coding for face recognition [C]// Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE Press, 2011: 625-632.

[5] Peng Yigang, Ganesh A, Wright J, *et al.* RASL: robust alignment by sparse and low-rank decomposition for linearly correlated images [J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2012, 34 (11): 2233-2246.

[6] Wagner A, Wright J, Ganesh A, *et al.* Towards a practical face

recognition system: robust registration and illumination by sparse representation [J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2012, 34 (2): 372.

[7] 杨荣根, 任明武, 杨静宇. 基于稀疏表示的人脸识别方法 [J]. 计算机学报, 2010, 37 (9): 267-269. (Yang Ronggen, Ren Mingwu, Yang Jingyu. Sparse representation based face recognition algorithm [J]. Computer Science, 2010, 37 (9): 267-269.)

[8] 平强, 庄连生, 俞能海. 姿态鲁棒的分块稀疏表示人脸识别算法 [J]. 中国科学技术大学学报, 2011, 41 (11): 975-981. (Ping Qiang, Zhuang Liansheng, Yu Nenghai. Pose-robust face recognition via part-based sparse representation [J]. Journal of University of Science and Technology of China, 2011, 41 (11): 975-981.)

[9] 郑轶, 蔡体健. 稀疏表示的人脸识别及其优化算法 [J]. 华东交通大学学报, 2012, 29 (1): 10-14. (Zheng Yi, Cai Tijian. Sparse representation face recognition and it's optimized algorithms [J]. Journal of East China Jiaotong University, 2012, 29 (1): 10-14.)

[10] 曾军英, 甘俊英, 翟懿奎. Gabor 字典及 l_0 范数快速稀疏表示的人脸识别算法 [J]. 信号处理, 2013, 29 (2). (Zhen Junying, Gan Junying, Zhai Yikui. Face recognition based on fast sparse representation of Gabor dictionary and l_0 norm [J]. Signal Processing, 2013, 29 (2).)

[11] 封睿, 李小霞. 基于 GLC-KSVD 的稀疏表示人脸识别算法 [J]. 兵器装备工程学报, 2014, 35 (4): 88-92. (Feng Rui, Li Xiaoxia. Sparse representation face recognition algorithm based on Gabor feature and label consistent K-SVD [J]. Journal of Ordnance Equipment Engineering, 2014, 35 (4): 88-92.)

[12] 马小虎, 谭延琪. 基于鉴别稀疏保持嵌入的人脸识别算法 [J]. 自动化学报, 2014, 40 (1): 73-82. (Ma Xiaohu, Tan Yanqi. Face recognition based on discriminant sparsity preserving embedding [J]. Acta Automatica Sinica, 2014, 40 (1): 73-82.)

[13] 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. (Hu Zhengping, Li Jing. Face recognition of joint sparse representation based on low-rank subspace recovery [J]. Acta Electronica Sinica, 2013, 41 (5): 987-991.)

[14] 朱杰, 杨万扣, 唐振民. 基于字典学习的核稀疏表示人脸识别方法

- [J]. 模式识别与人工智能, 2012, 25 (5): 859-864. (Zhu Jie, Yang Wankou, Tang Zhenmin. A dictionary learning based kernel sparse representation method for face recognition [J]. Pattern Recognition and Artificial Intelligence, 2012, 25 (5): 859-864.)
- [15] Wang Dong, Lu Huhcuan, Yang Mingsuan. Kernel collaborative face recognition [J]. Pattern Recognition, 2015, 48 (10): 3025-3037.
- [16] Fu Lijun, Chen Deyun, Lin Kezheng, *et al.* An improved SRC method based on virtual samples for face recognition [J]. Journal of Modern Optics, 2018 (99): 1-12.
- [17] He Lingxiao, Li Haiqing, Qi Zhang, *et al.* Dynamic feature matching for partial face recognition [J]. IEEE Trans on Image Processing, 2018, 28 (2): 791-802.
- [18] Zhu Pengfei, Zhang Lei, Hu Qinghua, *et al.* Multi-scale patch based collaborative representation for face recognition with margin distribution optimization [C]// Proc of European Conference on Computer Vision. Berlin: Springer-Verlag, 2012: 822-835.
- [19] Lei Yinjie, Guo Yulan, Hayat M, *et al.* A two-phase weighted collaborative representation for 3D partial face recognition with single sample [J]. Pattern Recognition, 2016, 52 (4): 218-237.
- [20] Wang Biao, Li Weifeng, Poh N, *et al.* Kernel collaborative representation-based classifier for face recognition [C]// Proc of IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver: IEEE Press, 2013: 2877-2881.
- [21] 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. (Zhang Zhelai, Ma Xiaohu. Face recognition of collaborative representation based on virtual samples [J]. Application Research of Computers, 2015, 32 (11): 3518-3520.)
- [22] 董吉文, 赵磊, 张亮. 核协同表示在人脸识别的遮挡问题中的应用 [J]. 计算机技术与发展, 2013, 23 (7): 141-143. (Dong Jiwen, Zhao Lei, Zhang Liang. Application of kernel collaborative representation in occlusion problem of face recognition [J]. Computer Technology and Development, 2013, 23 (7): 141-143.)
- [23] Vo D M, Lee S W. Robust face recognition via hierarchical collaborative representation [J]. Information Sciences, 2017, 432: 332-346.
- [24] Song Xiaoning, Feng Zhenhua, Hu guansheng, *et al.* Dictionary integration using 3d morphable face models for pose-invariant collaborative-representation-based classification [J]. IEEE Trans on Information Forensics & Security, 2016, 13 (11): 2734-2745.
- [25] Song Xiaoning, Yang Xibei, Shao Changbin, *et al.* Parity symmetrical collaborative representation-based classification for face recognition [J]. International Journal of Machine Learning & Cybernetics, 2017, 8 (5): 1485-1492.
- [26] Liu Shigang, Zhang Xinxin, Peng Yali, *et al.* Virtual images inspired consolidate collaborative representation-based classification method for face recognition [J]. Journal of Modern Optics, 2016, 63 (12): 1-8.
- [27] Yan K, Sukthankar R. PCA-SIFT: a more distinctive representation for local image descriptors [J]. Proc of Cvpr, 2004, 2 (2): 506-513.
- [28] Adankon M M, Cheriet M. Support vector machine [J]. Computer Science, 2002, 1 (4): 1-28.
- [29] Agrawal R, Gehrke J, Gunopulos D, *et al.* Automatic subspace clustering of high dimensional data for data mining applications [M]// ACM SIGMOD Record. 1998: 94-105. Whittaker J A, Thomason M G. A Markov Chain Model for Statistical Software Testing [M]. [S.l.]: IEEE Press, 1994.