

基于压缩金字塔核稀疏表示的人脸识别

周凯¹ 元昌安^{1,2} 覃晓² 郑彦¹ 苏杰波¹

(1. 广西大学计算机与电子信息学院, 南宁, 530004; 2. 广西师范学院计算机与信息工程学院, 南宁, 530001)

摘要: 人脸识别中光照、伪装及姿态等变化一直是富有挑战性的问题, 其中特征提取是很关键的一步。为提高人脸识别率, 结合压缩感知和空间金字塔模型, 本文提出了一种新的特征提取方法, 首先用尺度不变特征变换算法提取图像特征, 然后与随机生成的字典进行稀疏编码, 再用金字塔模型分层提取不同尺度空间的特征, 并用最大池融合特征, 最后运用核稀疏表示分类。在 Extended Yale B, AR 和 CMU PIE 人脸数据库上的实验结果表明, 该方法对于人脸图像的光照、伪装及姿态等变化有较强的鲁棒性, 而且该算法有较快的运行速度。

关键词: 人脸识别; 空间金字塔; 压缩感知; 稀疏表示

中图分类号: TP391 文献标志码: A

Face Recognition Based on Compressed Spatial Pyramid Model and Kernel Sparse Representation

Zhou Kai¹, Yuan Changan^{1,2}, Qin Xiao², Zheng Yan¹, Su Jiebo¹

(1. Computer and Electronic Information College, Guangxi University, Nanning, 530004, China; 2. Computer and Information Engineering, Guangxi Teachers Education University, Nanning, 530001, China)

Abstract: Face recognition is still challenging due to the large variations of facial appearance, caused by lighting, partial occlusions, head pose, etc. The feature extraction is a key step for face recognition. In order to improve the recognition rate of face recognition, we introduce a novel feature extraction technique for face recognition, which is a combination of compressed sensing and spatial pyramid model method. The scale invariant feature transform is first used to be a feature extractor to obtain facial features. Then by using sparse coding in the randomly generated dictionary, dimensionalities of those features are reduced. After the spatial pyramid is used to be a feature extractor to obtain different spatial scales, the max pool is used to integrate the features. Finally, the kernel sparse representation classifier is proposed to classify the features to complete the face recognition. The experimental results based on the Extended Yale B, AR and CMU PIE databases demonstrate that the method has a strong robustness in the illumination, pose and disguise variation with a faster running speed.

Key words: face recognition; spatial Pyramid; compressive sensing; sparse representation

引言

人脸识别在模式识别、机器视觉等领域一直是一个热门话题^[1,2], 人脸识别中特征提取是一个关键步骤, 好的特征提取算法, 不但可以帮助提高人脸识别算法的效率, 还可以改善人脸识别的准确度。人脸识别中有一些经典的特征提取方法, 如主成分分析(Principal component analysis, PCA)、线性判别分析(Linear discriminant analysis, LDA)等^[3,4], 可是这些方法只在理想的情况下识别率高。为改善特征提取效果, 文献[5,6]分别提出了尺度不变特征变换方法(Scale invariant feature transform, SIFT)和词袋模型, 其中词袋模型是采用SIFT提取图像关键点和特征, 然后用K-均值聚类来得到特征向量, 因为词袋模型忽略了特征的空间信息并且使特征无序, 因而人脸识别的效果不是很理想; 文献[7]将词袋模型与金字塔匹配(Spatial pyramid model, SPM)方法结合, 虽然SPM可以使图像特征有序并且包含一定空间信息, 使得改进的算法性能有所提高, 但空间信息的丢失以及聚类大小的选取依然没有得到很好的解决; 文献[8]提出的(Sparse coding spatial pyramid matching, SCSPM)算法是通过从训练样本中学习更新字典的方法来代替K均值聚类, 使得算法识别率有很大改善, 可是学习更新字典花费时间太长, 运算效率低。近年来压缩感知^[9]和稀疏表示(Sparse representation, SR)作为一个研究热点被广泛用于模式识别领域, 稀疏表示是把信号在一过完备字典上分解, 将其转变成稀疏系数矩阵, 通常字典中基的选取有傅里叶基、小波基和随机矩阵等^[10]。Wright J等^[11]将训练样本作为字典, 首先将SR应用到人脸识别, 并且得到较好的效果。由于稀疏表示受线性条件的制约, 不能很好地表现数据, 所以有学者将核函数引入到稀疏表示中, 可以把数据投影到高维的特征空间更好地进行分类^[12,13]。

针对上述问题, 受到压缩感知理论的启发, 本文结合压缩感知和空间金字塔的思想, 提出了一种新的特征提取算法——压缩空间金字塔模型(Compressed spatial pyramid model, CSPM), 首先用SIFT提取图像特征关键点后, 通过与随机矩阵进行编码。然后结合SPM算法分层提取不同尺度的信息, 经最大池算法融合特征^[8], 最后用核稀疏表示(Kernel sparse representation, KSRC)进行分类。本文提出的算法不仅能克服人脸各种因素的变化而且运算速度相比其他算法也有很大提升。

1 相关工作

1.1 压缩感知

压缩感知^[9]可以将图像信息转化为稀疏系数矩阵表示, 假如图像集有 k 类, 其中第*i*类训练样本有 n_i 个, 每一个训练样本组成字典的一列, 即字典的一个原子, 定义一个有*i*类训练样本组成的字典 $\Phi_i = [\phi_{i,1}, \phi_{i,2}, \dots, \phi_{i,n_i}]$, 其中 $\phi_{i,j} \in \mathbb{R}^m$ 表示第*i*类的第*j*个样本, m 为字典原子的维数, 如果给一个测试样本 y 也属于第*i*类, 则 y 可以通过字典 Φ_i 线性表示为

$$y = c_{i,1}\phi_{i,1} + c_{i,2}\phi_{i,2} + \dots + c_{i,n_i}\phi_{i,n_i} \quad (1)$$

式中: $c_{i,j}$ 为稀疏系数, 表示重构 y 时第*j*个样本的权重; 对于所有的*k*类样本组成的字典矩阵 $\Phi = [\Phi_1, \Phi_2, \dots, \Phi_k]$, 其中 $\Phi \in \mathbb{R}^{m \times N}$; N 为所有类的样本总数, 这样 y 可以重新改写为

$$y = \Phi X \quad (2)$$

式中: $X = [0, \dots, 0, c_{i,1}, \dots, c_{i,n_i}, 0, \dots, 0]^T$ 表示一个稀疏系数矩阵。理想情况下, 样本 y 只与同类的训练样本有关, 而其他不相关的稀疏系数全部为零, 但是一般情况下, 表达式 $y = \Phi X$ 欠定, 求出解的结果不唯一, 所以通常用最小化 l_1 范数问题来求解, 其拉格朗日表示为

$$\min_x \frac{1}{2} \|y - \Phi x\|_2^2 + \lambda \|x\|_1 \quad (3)$$

式中: λ 为拉格朗日乘数。

1.2 空间金字塔匹配

空间金字塔模型^[7]是为了解决无序图像特征集合之间的匹配问题,以网格的方式将图像特征空间由粗到细分割成金字塔形式,然后在金字塔的每层进行特征向量集的匹配,最后将每层的匹配结果进行加权相加。假如一幅图像分为 $0, \dots, L$ 层,第 l 层有 2^{2l} 个区域, H_x^l 和 H_y^l 为 l 层上 x 和 y 的直方图, $H_x^l(i)$ 和 $H_y^l(i)$ 分别表示 x 和 y 落在第 i 个区域内的像素个数,所以图像空间金字塔第 l 层的匹配函数可表示为

$$I(H_x^l, H_y^l) = \sum_{i=0}^{D-1} \min(H_x^l(i), H_y^l(i)) \quad (4)$$

式中: $D=2^{2l}$ 。因为网格的划分由细到粗,第 l 层的匹配数目包含了第 $l+1$ 层的匹配数目,所以第 l 层的有效匹配数目应为: $I^l - I^{l+1}$,其中 $l=0, \dots, L-1$ 。 I^l 为 $I(H_x^l, H_y^l)$ 的简写。并且在计算总匹配数时,给第 l 层匹配数加上一个权值系数 $1/2^{L-l}$,最后得到所有层的匹配函数为

$$K^L(\mathbf{X}, \mathbf{Y}) = I^L + \sum_{l=0}^{L-1} \frac{1}{2^{L-l}} (I^l - I^{l+1}) = \frac{1}{2^{L-L}} I^0 + \sum_{l=1}^L \frac{1}{2^{L-l+1}} I^l \quad (5)$$

2 本文算法

2.1 CSPM 特征提取算法

首先将一幅图像分割成不同的块,然后每一块用局部特征提取算法,如 SIFT 算法进行特征提取,接下来传统的算法如用词袋模型^[6]对块进行 K-均值聚类得到字典,SCSPM 算法^[14]是通过字典学习得到字典,然后再求出每一块对于字典的一个映射。而本文算法不再通过聚类或者学习得到字典,因为样本最终都是通过一个字典映射得到稀疏系数,用稀疏系数来表示样本特征。

所以本文利用压缩感知的思想,系统随机生成一个随机字典,同样样本通过随机字典映射,得到稀疏系数,从而省去了得到和更新字典的时间,而且因为人脸图像的遮挡、部分信息的丢失,学习过的字典并不能完全表示样本信息,随机字典则不受影响。假如图像的每一特征块与随机字典通过稀疏表示求解,得到稀疏系数矩阵,最后和 SCSPM 算法利用 SPM 算法和最大池相同,将不同空间位置的信息融合得到图像的特征编码。

假如系统生成的随机字典为 \mathbf{B} ,一幅图像 y 分割为 N 块, $\mathbf{H}=[h_1, \dots, h_N]$, h_i 为 y 图像 SIFT 提取的第 i 块特征,一幅图像的每一局部块系数为

$$\hat{\mathbf{s}} = \arg \min_s \frac{1}{2} \| \mathbf{H} - \mathbf{BS} \|_F^2 + \lambda \| \mathbf{s} \|_1 \quad (6)$$

设 $\hat{\mathbf{s}} = [\hat{s}_1, \dots, \hat{s}_N]$ 为利用式(6)得到的稀疏矩阵; \hat{s}_i 为对应 h_i 块的稀疏系数。为了融合稀疏系数,本文用最大池方法,因为最大池对图像变换以及噪声有更好的鲁棒性,其定义为

$$z_k = \max\{|\hat{s}_{k1}|, \dots, |\hat{s}_{kN}|\} \quad (7)$$

式中: z_k 表示池向量 \mathbf{Z} 的第 k 个元素; \hat{s}_{kj} 表示为稀疏特征矩阵 $\hat{\mathbf{s}}$ 的 k 行、 j 列元素。

利用空间金字塔模型,为得到一幅图像不同的空间位置和尺度大小,可将一幅图像分 L 层,每层 2^{2L} 块, L_i 表示第 i 层, $i=0, 1, \dots, L$,每层的所有块通过上述方法进行处理,假如用特征池映射得到该尺度特征向量的最大池为 z_k ,将得到的不同尺度和区域的特征编码串接起来,最后作为这幅图像的特征向量。CSPM 特征提取方法的流程图如图 1 所示。

2.2 CSPM+KSRC 算法

核方法可以将非线性不可分的特征映射到高维特征空间,在高维特征空间不同的类可以很容易分开,对于直方图统计特征,一般可使用卡方核函数^[15]或者直方图交叉核函数^[16],其中直方图交叉核函数

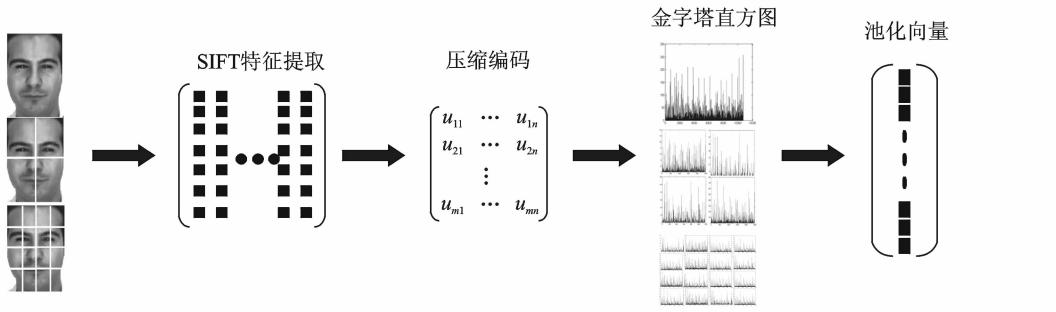


图 1 CSPM 特征提取流程图

Fig. 1 Flowchart of CSPM feature extraction

表示如下

$$K(\mathbf{X}_i, \mathbf{Y}_j) = \sum_{n=1}^m \min(a_n, b_n) \quad (8)$$

式中: $\mathbf{X}_i, \mathbf{Y}_j$ 为两个维度为 m 的特征向量; a_n, b_n 分别为 $\mathbf{X}_i, \mathbf{Y}_j$ 特征向量的特征值。

假如用 CSPM 算法特征提取后得到的训练集为 \mathbf{A} , 测试样本为 $\mathbf{Y}=[y_1, \dots, y_N]$, 以第 i 个测试样本为例, y_i 可以通过矩阵 \mathbf{A} 表示为

$$\min_w \|\phi(y_i) - \phi(\mathbf{A})\mathbf{w}_i\|_2^2 \quad \text{s. t.} \quad \|\mathbf{w}_i\|_{l_p} \leqslant \sigma \quad (9)$$

式中: \mathbf{w}_i 表示稀疏系数; ϕ 为核函数; 为求稀疏系数, 将式(9)展开得到, 即

$$\hat{\mathbf{w}} = \arg \min_w \sum_{i=1}^N k(y_i, y_i) + \mathbf{w}^T \sum_{i=1}^N k(\mathbf{A}, \mathbf{A})\mathbf{w} - 2\mathbf{w}^T \sum_{i=1}^N k(\mathbf{A}, y_i) \quad \text{s. t.} \quad \|\mathbf{w}_i\|_{l_p} \leqslant \sigma \quad (10)$$

式中: y_i 为第 i 个测试样本; $\sum_{i=1}^N k(y_i, y_i)$ 为 y_i 与 y_i 的直方图交叉核。

最后分类通过最小化残差 e 来实现, 有

$$e_j = \|\phi(y_i) - \phi(\mathbf{A})\hat{\mathbf{w}}_j\|_2^2 = \min_j \left\{ \sum_{i=1}^N k(y_i, y_i) + \mathbf{w}_j^T \sum_{i=1}^N k(\mathbf{A}, \mathbf{A})\hat{\mathbf{w}}_j - 2\hat{\mathbf{w}}_j^T \sum_{i=1}^N k(\mathbf{A}, y_i) \right\} \quad (11)$$

式中: $\hat{\mathbf{w}}_j$ 为第 j 类的稀疏系数。

2.3 CSPM-KSRC 算法步骤

输入: 训练集 Φ , 测试集 $\mathbf{Y}=[y_1, \dots, y_N]$;

输出: \mathbf{Y} 的类标签; 算法步骤为:

(1) 将训练集 Φ 和测试集 \mathbf{Y} 图像分块后用 SIFT 特征提取。

(2) 生成随机字典 \mathbf{B} 。

(3) 通过随机字典 \mathbf{B} , 求出图像集的稀疏表示: $\hat{\mathbf{S}} = \arg \min_s \frac{1}{2} \|\mathbf{H} - \mathbf{BS}\|_F^2 + \lambda \|\mathbf{S}\|_1$ 。

(4) 用 SPM 求图像不同尺度的稀疏编码 $\hat{\mathbf{S}}$, 最大池融合得到训练集和测试集特征向量 \mathbf{A} 和 $\mathbf{Y}=[y_1, \dots, y_N]$ 。

(5) 求解稀疏系数 $\hat{\mathbf{w}}$

$$\hat{\mathbf{w}} = \arg \min_w \sum_{i=1}^N k(y_i, y_i) + \mathbf{w}^T \sum_{i=1}^N k(\mathbf{A}, \mathbf{A})\mathbf{w} - 2\mathbf{w}^T \sum_{i=1}^N k(\mathbf{A}, y_i)。$$

(6) 分类

$$\text{identity}(y_i) = \arg \min_j \left\{ \sum_{i=1}^N k(y_i, y_i) + \hat{\mathbf{w}}_j^T \sum_{i=1}^N k(\mathbf{A}, \mathbf{A})\hat{\mathbf{w}}_j - 2\hat{\mathbf{w}}_j^T \sum_{i=1}^N k(\mathbf{A}, y_i) \right\}。$$

3 实验仿真

为了证明上述算法的有效性,算法将在 Extended Yale B, AR 和 CMU PIE3 个人脸库上分别进行光照、伪装及姿势等实验,并与文献[11]的 SRC 算法、文献[7]中提出的特征提取算法 SPM 以及文献[8]提出的 SCSPM 算法进行比较,SRC 算法用 PCA 降到 300 维。实验中随机字典 B 大小的选择为 300, SPM 算法 K 聚类大小为 300,SCSPM 算法中字典大小也为 300,支持向量机(Support vector machine, SVM)采用直方图交叉核。实验平台和环境为 Matlab2014,Windows7 操作系统,Intel i5 处理器,主频 2.4 GHz。

3.1 Extended Yale B 数据库实验

Extended Yale B 数据库包含了 38 个人在不同光照下的人脸图像,每人约 64 张图像总共有 2 414 幅正面人脸图像,部分人脸图像如图 2 所示。为简化特征提取复杂度,将人脸规格化为 96×84 像素大小的图像,随机选取一半做为测试样本,训练样本 N_{tr} 的选取以及各算法的识别率如表 1 所示。

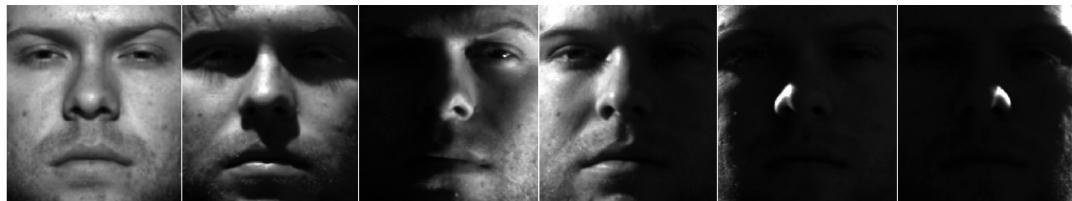


图 2 Extended Yale B 部分光照人脸图像

Fig. 2 Some face images of a subject from the Extended Yale B database

表 1 不同算法在 Extended Yale B 数据库上识别率的比较

Tab. 1 Face recognition results on the Extended Yale B database

%

N_{tr}	SRC	SPM+SVM	SCSPM+SVM	CSPM+SVM	SPM+KSRC	SCSPM+KSRC	CSPM+KSRC
10	89.96	79.68	83.38	80.34	86.26	95.88	93.09
15	95.06	89.88	94.24	89.88	93.91	98.76	97.53
25	96.87	94.24	98.27	96.62	97.20	99.75	99.01

从表 1 可以看出,随着训练样本的增加,各算法的识别率也相应提高,当训练样本数为 950 时,SCSPM 和本文算法的识别率最高都达到了 99%,这两种方法结合 KSRC 分类算法的识别率明显高于其他算法,虽然 SCSPM 算法识别率略高出本文算法,但本文方法相对于 SPM 算法还是有一定的优势,说明在一定程度上本文算法能克服光照对人脸识别的影响。

3.2 AR 数据库实验

AR 数据库中包含不同光照、表情和伪装变化的正面人脸图像 2 600 幅,共 100 人,每人 26 幅图像,部分图像如图 3 所示。AR 数据库分为两部分,第 1 部分的前 1~7 幅图像是表情、光照的变化,本文用来做训练集(700 张)然后各取第 1 部分的第 8~10 幅戴眼镜(眼镜 1)和第 11~13 幅戴围巾(围巾 1)人脸图像(各 300 张),第 2 部分的第 8~10 幅戴眼镜(眼镜 2)和第 11~13 幅戴围巾(围巾 2)人脸图像(各 300 张),分别来做测试集,并将人脸图像规格化为 83×60 像素大小,各算法识别率如表 2 所示。



图 3 AR 数据库中部分人脸图像

Fig. 3 Some face images of a subject from the AR database

表 2 不同算法在 AR 数据库上结果的比较

Tab. 2 Face recognition results on the AR database

图像	SRC	SPM+SVM	SCSPM+SVM	CSPM+SVM	SPM+KSRC	SCSPM+KSRC	CSPM+KSRC	%
眼镜 1	65.03	66.67	87.33	94.14	71.36	97.34	98.32	
围巾 1	76.33	66.58	86.01	90.94	71.34	96.32	97.33	
眼镜 2	31.67	34.10	55.32	64.91	43.37	73.00	80.96	
围巾 2	51.06	25.98	56.04	66.13	42.03	82.67	87.02	

由于 AR 数据库中有不同光照、表情和伪装的变化,而且图像噪声比较大,使得从样本中学习到的字典并不能很好地表示样本信息。所以从表 2 中可以看出,本文算法明显优于 SCSPM 算法。同时因为人脸的遮挡使得图像有用的局部信息很少,虽然用 SIFT 分块提取了特征,但用词袋模型映射编码后,丢失了很多有用的空间特征信息,所以导致 SPM 特征提取的算法识别率远低于 SCSPM 和本文算法,实验结果表明,本文算法对于遮挡表现出较好的性能。

3.3 CMU PIE 数据库实验

CMU PIE 库约有 11 560 张人脸图像,取自 68 个不同的人,每人约 170 张,图片有不同的姿态、表情和光照变化,本实验将所有图像集随机平均分为两部分:测试集和训练集,部分人脸图像如图 4 所示。为简化特征提取复杂度,将人脸规格化为 64×64 像素大小的图像。

在总共 68 类中,每类选取不同样本个数进行训练,用 KSRC 和 SVM 分类算法得到各方法的识别率如图 5(a,b)所示,从图中可以看出,各算法的识别率基本随着训练集的增加而增加,SCSPM 和本文方法算法识别率明显优于 SPM 方法,而且

对于同一特征方法而言,KSRC 分类算法也要优于 SVM。同时当训练集个数为 5 440 时,本文的特征提取方法在 KSRC 和 SVM 分类算法下的识别率分别达到了 99.52% 和 98.71%,基本和 SCSPM 算法的 99.77% 和 99.08% 不相上下,说明本文算法能克服人脸光照、姿态及表情等变化。

3.4 算法效率比较

表 3 为 3 种特征提取算法在 3 个数据库上运行的平均时间,从表 3 可以看出,本文方法明显要快于其他方法,从实验中发现,SPM 算法的主要时间花费在 K 聚类更新得到字典上。而 SCSPM 除了要更新



图 4 CMU PIE 数据库中部分人脸图像

Fig. 4 Some face images from the CMU PIE database

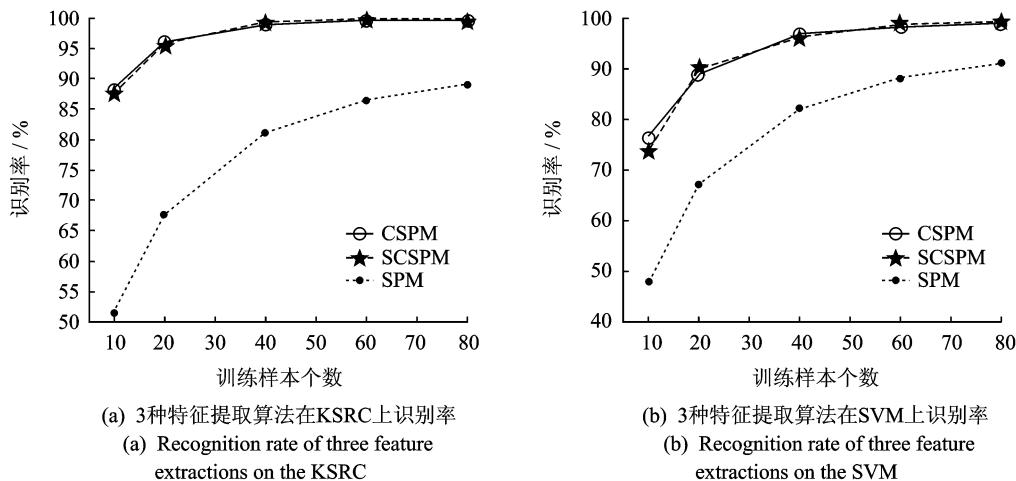


图 5 CMU PIE 中不同训练样本数下各算法识别率的比较

Fig. 5 Recognition rate of different training samples from CMU PIE database

表 3 3 种算法在 3 个数据库上的平均时间比较

Tab. 3 Three algorithms comparison of average time on the three databases s

算法	Extended Yale B 数据库	AR 数据库	CMU PIE 数据库
SPM	0.218 4	0.180 0	0.145 6
SCSPM	0.431 7	0.315 7	0.310 3
本文	0.192 1	0.100 1	0.115 0

字典以外,还需要通过最优算法求稀疏系数,从而导致算法耗时最长。

图 6 是单独选取 AR 数据库上样本数来作为比较,图中可以看出,本文算法因为不需要从训练样本中学习得到字典,特征提取时间随着样本数基本是线性增加。而 SPM 和 SCSPM 因为要花费大量时间在学习得到字典上,使得特征提取时间远大于本文方法。

4 结束语

本文结合空间金字塔与压缩感知的思想,提出了一种压缩金字塔核稀疏表示模型(CSPM+KSRC),该方法用随机字典代替传统词袋模型中字典的生成,将信号在随机字典上进行分解。实验结果表明,该算法不仅对人脸光照、姿态和伪装等变化有较强的鲁棒性,同时运行速度较快,在 3 个标准人脸库上证明了 CSPM+KSRC 算法的有效性。进一步提升算法性能将其用到真实生活中是未来工作的重点。

参考文献:

- [1] 杨军,袁红照,刘妍丽. 基于样本扩张和双子空间决策融合的单样本人脸识别算法[J]. 数据采集与处理,2015,30(1):148-154.

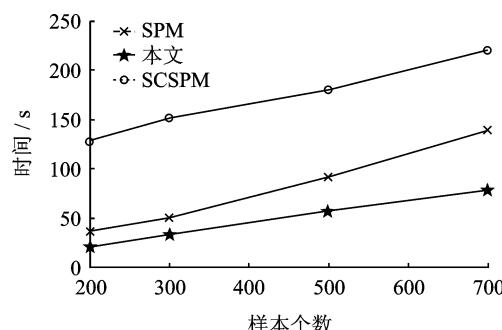


图 6 AR 数据库特征提取时间

Fig. 6 Feature extraction time of the AR database

- Yang Jun, Yuan Hongzhao, Liu Yanli. Algorithm for single sample face recognition based on sample augments and double subspace decision fusion[J]. *Journal of Data Acquisition and Processing*, 2015, 30(1): 148-154.
- [2] 徐志鹏, 黄敏, 朱启兵. 基于嵌入式的近红外人脸识别系统设计[J]. *数据采集与处理*, 2015, 30(1): 211-218.
- Xu Zhipeng, Huang Min, Zhu Qibing. Design of near-infrared face recognition system based on embedded technique[J]. *Journal of Data Acquisition and Processing*, 2015, 30(1): 211-218.
- [3] Ming D, Sankaranarayanan A C, Chellappa R. Robust face recognition from multi-view videos[J]. *IEEE Biometrics Compendium*, 2014, 3(23): 1105-1117.
- [4] Turk M, Pentland A. Eigenfaces for recognition[J]. *Journal of Cognitive Neuroscience*, 1991, 3(1): 71-86.
- [5] Belhumeur P, Hespanha J, Kriegman D. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1997, 19(7): 711-720.
- [6] Cox D, Pinto N. Beyond simple features: A large-scale feature search approach to unconstrained face recognition [C]// IEEE International Conference on Automatic Face & Gesture Recognition and Workshops(FG). Santa Barbara: IEEE, 2011: 8-15.
- [7] Nowak E, Jurie F, Triggs B. Sampling strategies for bag-of-features image classification[C]// European Conference on Computer Vision. Graz, Austria: Springer Berlin Heidelberg, 2006: 490-503.
- [8] Lazebnik S, Schmid C, Ponce J. Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories [C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2006: 2169-2178.
- [9] Yang J, Yu K, Gong Y, et al. Linear spatial pyramid matching using sparse coding for image classification[C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Miami, USA: IEEE, 2009: 1794-1801.
- [10] Donoho D L. Compressed sensing[J]. *IEEE Trans on Information Theory*, 2006, 52(4): 1289-1306.
- [11] Candès E. Compressive sampling[C]// Proc of the Int Congress of Mathematicians. Madrid, Spain: European Mathematical Society, 2006, 3: 1433-1452.
- [12] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation[J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210-227.
- [13] Gao S, Tsang W H, Chia L T. Kernel sparse representation for image classification and face recognition[C]// IEEE Transactions on Image Processing. Heraklion, Greece: Springer Berlin Heidelberg, 2013, 22: 423-434.
- [14] Barla A, Odone F, Verri A. Histogram intersection kernel for image classification[C]// Proceedings of the International Conference on Image Processing. Barcelona, Spain: IEEE, 2003, 9(2): 513-516.
- [15] Yin J, Liu X, Jin Z, et al. Kernel sparse representation classification[J]. *Neurocomputing*, 2012, 77(1): 120-128.
- [16] Bosch A. Image classification for a large number of object categories[D]. Girona: University of Girona, 2007.

作者简介:



周凯(1991-),男,硕士研究生,研究方向:模式识别、图像处理,E-mail: 18376767366@163.com。



元昌安(1964-),男,教授,研究方向:模式识别、数据挖掘。



覃晓(1973-)(通讯作者),女,副教授,研究方向:模式识别、图像处理,E-mail: 18376767366@163.com



郑彦(1993-),女,硕士研究生,研究方向:模式识别、图像处理。



苏杰波(1984-),男,硕士研究生,研究方向:机器学习、入侵检测。