

特征采样和特征融合的子图像人脸识别方法^{*}

朱玉莲^{1,2+}, 陈松灿²

¹(南京航空航天大学 计算中心, 江苏 南京 210016)

²(南京航空航天大学 计算机科学与技术学院, 江苏 南京 210016)

Sub-Image Method Based on Feature Sampling and Feature Fusion for Face Recognition

ZHU Yu-Lian^{1,2+}, CHEN Song-Can²

¹(Computer Center, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

²(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

+ Corresponding author: E-mail: lianyi_1999@nuaa.edu.cn

Zhu YL, Chen SC. Sub-Image method based on feature sampling and feature fusion for face recognition. *Journal of Software*, 2012, 23(12): 3209–3220 (in Chinese). <http://www.jos.org.cn/1000-9825/4199.htm>

Abstract: In this paper, a sub-image method based on feature sampling and feature fusion (called as RS_SpCCA) is proposed. RS_SpCCA first performs a random subspace method in sub-images which are partitioned in a deterministic way. Then, the method obtains correlation features by fusing sampled features and global feature extracted by certain feature extraction method and finally, constructs component classifiers on correlation features. In this method, the purpose of sampling feature is to construct more diverse component classifiers, and the purpose of the fusing feature is to make good use of the global information. The experimental results on AR, Yale and ORL three face image databases show that sub-image method based on feature sampling and feature fusion (RS_SpCCA) is superior to both SpCCA and Semi-RS which only use feature sampling or feature fusion.

Key words: canonical correlation analysis (CCA); face recognition; information fusion; small sample size; sub-image method; feature sampling

摘要: 提出一种基于特征采样和特征融合的子图像人脸识别方法(RS-SpCCA)。首先,对子图像进行特征采样;然后,将全局特征和采样后的特征使用 CCA 进行信息融合,以获取包含全局特征和局部特征的相关特征;最后,在相关特征上构建分量分类器。在该方法中,特征采样是为了构建更多且多样的分量分类器;而引入特征融合思想是为了充分利用图像的全局特征。AR, Yale 和 ORL 这 3 个数据库上的实验结果表明,基于特征采样和特征融合的子图像方法(RS-SpCCA)优于单纯的信息融合方法(SpCCA)和特征采样方法(Semi-RS)。

关键词: 典型相关分析;人脸识别;信息融合;小样本问题;子图像;特征采样

中图法分类号: TP391 **文献标识码:** A

人脸识别作为机器视觉与模式识别领域的研究热点之一,近几十年来得到越来越多的关注。在人脸识别中,

* 基金项目: 国家自然科学基金(60973097, 61035003); 南京航空航天大学基本科研业务费专项科研项目(ns2010233)

收稿时间: 2011-08-02; 修改时间: 2011-11-02; 定稿时间: 2012-02-15; jos 在线出版时间: 2012-03-22

CNKI 网络优先出版: 2012-03-22 14:46, <http://www.cnki.net/kcms/detail/11.2560.TP.20120322.1446.001.html>

人脸特征描述是关键步骤之一.一般而言,人脸特征分全局特征和局部特征.其中:全局特征主要描述人脸整体属性(如肤色),用来进行粗略的匹配;而局部特征主要描述人脸细节变化(如疤痕),用来进行精细的确认^[1,2].大量的全局和局部特征提取方法^[1-10]已被提出,其中经典的全局特征方法包括 PCA^[3],LDA^[4]和 LPP^[10]等.PCA 通过最大化样本离散度获取具有最佳重构性能的特征,LDA 通过最小化类内散度与类间散度的比值来获取具有最佳判别能力的特征,而 LPP 则通过最大限度地保留样本间的几何结构来获得潜在判别能力的特征.然而,它们在获取全局特征的同时缺乏对局部变化(如遮挡、光照)的不敏感性及鲁棒性.为获取更多局部特征并尽量克服对局部变化的敏感性问题,基于局部特征方法,如 Gabor 小波法^[5]、LBP^[6]和子图像方法^[7-9,11-17]等,被广泛应用于人脸识别.Gabor 小波方法通过提取图像特定区域内的多尺度、多方向空间频域特征放大眼睛、鼻子和嘴以及其他一些局部特征^[18];LBP 通过对局部区域进行二值编码获取局部的纹理信息;而子图像方法则通过对原始图像进行划分,然后分别在每个子图像中提取特征来获取局部特征.

由于子图像方法能够有效解决小样本问题,提高算法对光线、遮挡等变化因素的鲁棒性,而且简单、直观,易推广至其他的全局或局部特征提取方法,所以近几年来,基于子图像的方法得到了很大的重视^[7-9,11-17].

Gottumukkal 通过提取和使用人脸图像的局部信息提出了模块 PCA(mPCA)方法^[11].在 mPCA 中,人脸首先被分成若干相等大小的子块,然后将所有子块组成的子图像集看作新的训练集,最后在该新训练集上执行 PCA 以提取特征.几乎同时,Chen 和 Zhu 提出了子模式 PCA(SpPCA)^[8].与 mPCA 不同的是,SpPCA 分别从每个子图像中提取局部特征,然后将所获取的局部特征串联起来形成最后的全局特征.随后,Tan 等人提出了自适应加权的 Aw-SpPCA 方法^[12],该方法在每个子图像集上构建一个分类器,然后分别对未知样本的相应子图像块进行分类,最后使用加权投票方式融合所有分类结果.在文献[8,11,12]的基础上,大量关于子图像的工作相继发表^[13-17].这些方法的共同点是通过某种特定方法获取子图像的特征,然后在每个子图像特征上构建一个分类器,它们均获得了某种程度的成功.然而,它们所构建的分类器均是单纯地基于局部特征或全局特征,而并未充分利用局部特征间或局部与全局特征间的关系.在人脸识别中,全局特征和局部特征所描述的内容和作用各不相同,基于全局特征的方法往往缺乏对人脸光照、表情和遮挡等变化的鲁棒性;而单纯基于局部特征的方法又忽略了局部特征间的联系,从而损失了部分全局特征.因此,融合全局和局部特征便成为人脸识别的研究方向之一^[1,2,19-21].洪泉等人提出了一种基于特征融合的人脸识别方法 SpCCA^[19].该方法将人脸图像划分成若干块,分别从整个人脸图像和每个子图像中提取出全局特征和局部特征,将局部特征和全局特征利用典型相关分析(CCA)^[22]进行融合,最后使用投票方法进行最终决策.与传统的子图像方法相比,SpCCA 的分类器融合了局部和全局的相关特征,更多地利用了全局特征和局部特征间的互补关系,因此获得了更好的性能.

子图像方法为每个子图像构建一个分量分类器,然后通过多分类器集成形成最后决策,因此本质上为多分类器系统.然而,其分量分类器的个数及各分类器间的多样性完全由子图像划分形式决定.所以当子图像划分形式发生变化时,其性能可能会受到严重影响.随机子空间方法(RMS)^[23]是一种构建多样分量分类器的重要方法,它不受任何约束地随机地从整个特征集中选取特征以获得不同的特征子集,并在该子集上训练出不同的分类器.目前,随机子空间方法被广泛应用于人脸识别中^[7,9,24-26].Wang 和 Tang 首次将随机子空间方法应用于人脸识别领域^[26];Zhang 等人为判别分析方法构建了最优的随机子空间维数^[25];我们则将特征随机采样应用于人脸子图像,提出了 Semi-RS 方法^[7].Semi-RS 不仅获得了比文献[25-27]更优的性能,而且有效地增加了分量分类器间的多样性.

鉴于随机子空间和信息融合方法在人脸识别中的成功应用,我们提出了基于特征采样和特征融合的子图像方法(RS-SpCCA),通过特征采样构建更多且多样的分量分类器,而通过特征融合更充分利用局部特征和全局特征间的关系.在 AR,Yale,ORL 这 3 个数据库上的实验结果表明:基于特征采样和信息融合的 RS-SpCCA 方法优于单纯的信息融合方法(SpCCA)和特征采样方法(Semi-RS);更重要的是,相对于 SpCCA 方法,RS-SpCCA 对子图像大小的敏感性更小.

本文第 1 节对文中的方法进行详细描述.第 2 节给出在 3 个标准数据集上的实验结果并讨论参数选择问题.最后,第 3 节对本文进行总结.

1 特征采样和特征融合子图像方法(RS-SpCCA)

RS-SpCCA 在子图像基础上同时引入特征采样和信息融合思想,希望构建更多分量分类器并充分利用局部特征与全局特征间的关系.RS-SpCCA 方法可分为如下步骤:

- (1) 将人脸图像划分为子图像;
- (2) 对每个子图像进行特征的随机采样;
- (3) 通过某种方法(如 PCA,LDA 等)提取人脸全局特征;
- (4) 使用 CCA 将全局特征与从子图像上采样的特征进行融合;
- (5) 对未知样本进行分类判别.

1.1 子图像划分

通常有两种不同的划分方法:一种是局部器官法,另一种是局部区域法.局部器官法主要根据人脸的特征器官来划分,如眼睛、嘴巴、鼻子等区域.由于这种划分往往依赖于一定的特征检测方法或需某种程度的人工干预,所以在操作上有一定限制;而局部区域法则根据图像具体坐标位置来划分,由于该方法往往能获得比局部器官法更好的识别效果^[28],因此本文采用最简单的不重叠相等大小的矩形区域进行图像划分.

设原始训练集包含 N 个大小为 $m \times n$ 的图像.首先将每个图像按照相同划分方式将其分割成 L 个相等大小的子图像(每个子图像的大小为 $p=m \times n/L$);然后将所有图像中相同位置的子图像转换成列向量并进行组合,形成一个子图像集.由于每个图像共有 L 个子图像,所以对整个训练集而言,共产生 L 个子图像训练样本集 $\{T_i\}_{i=1}^L$.子图像集的构建过程如图 1 所示.

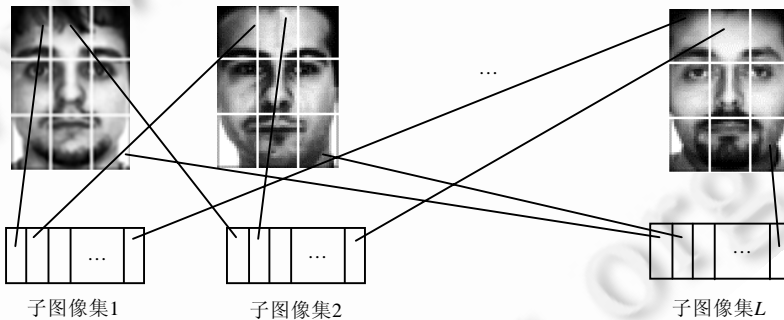


Fig.1 Construction of sub-image set

图 1 子图像构造

1.2 图像特征的随机采样

RS-SpCCA 在每个子图像集上执行随机采样,因此对第 i 个子图像集 T_i 而言,根据随机子空间法的思想,从 $1 \sim p$ (p 为子图像大小)中随机产生 p^* ($p^* < p$) 维索引向量 $v_i^1 = \{I_1^1, I_2^1, \dots, I_{p^*}^1\}$, 然后根据 v_i^1 从 T_i 中提取特征并将其表示为 T_i^1 .该过程反复独立地执行 K 次(K 为子图像集中分类器数目),相应地获得了 K 个特征子集 T_i^k ($k=1,2,\dots,K$).由于训练集中包含 L 个子图像集,因此共可生成 $L \times K$ 个特征子集.

1.3 全局特征提取

全局特征提取的方法有多种,PCA,LDA 和 LPP 均是比较经典的全局特征提取方法.为了与文献[7,19]中的实验条件保持一致,文中亦采用 PCA 进行全局特征提取.设 $X=[x_1, x_2, \dots, x_N]$ 包含 N 个训练样本,其中, $x_i \in R^d$ ($d=m \times n, i=1,2,\dots,N$) 表示第 i 个训练样本, S 是 X 的总体散度矩阵.使用 PCA 提取全局特征,可首先通过求解方程 $SW=WA$ 来获取投影矩阵 W (其中, A 是由 S 的所有特征值所组成的对角矩阵);然后将 N 个训练样本分别投影至 W 上,从而获取相应全局特征 $F=W^T X$.

1.4 信息融合

RS-SpCCA 使用 CCA 融合全局特征 F 和每个采样的特征子集,即融合特征组 $\{F, T_i^k (k=1,2,\dots,K,i=1,2,\dots,L)\}$. 设 t 为集合 $\{T_i^k\}_{(k=1,2,\dots,K,i=1,2,\dots,L)}$ 中任意元素,则根据 CCA 思想,期望找到两组基向量 w 和 v 以最大化 $t^T w$ 和 $F^T v$ 间的相关系数,且各分量间尽量不相关.该问题可通过最大化式(1)获得:

$$\rho = \frac{E(w^T t F^T v)}{\sqrt{E(w^T t t^T w)} \sqrt{E(v^T F F^T v)}} \quad (1)$$

其中, T 表示转置.通过一些转换或化简,该问题可通过求解以下特征值问题获得:

$$\begin{cases} C_u^{-1} C_{tF} C_{FF}^{-1} C_{Fi} w = \lambda w \\ C_{FF}^{-1} C_{Fi} C_u^{-1} C_{tF} v = \lambda v \end{cases} \quad (2)$$

其中, $\begin{bmatrix} C_u & C_{tF} \\ C_{Fi} & C_{FF} \end{bmatrix} = E \left[\begin{pmatrix} t \\ F \end{pmatrix} \begin{pmatrix} t \\ F \end{pmatrix}^T \right]$. 若设 $W_i = [w_1, w_2, \dots, w_d]$ 和 $V_F = [v_1, v_2, \dots, v_d]$ 分别表示前 d 个特征值所对应的特征向量,那么 $t^T W_i$ 或 $F^T V_F$ 均可作为提取的特征用于分类.其中, $t^T W_i$ 是融合了全局特征的局部特征,而 $F^T V_F$ 是融合了局部特征的全局特征.本文使用 $t^T W_i$ 即局部特征来作为判别向量.通过相同的方式,利用 CCA 分别将 $\{T_i^k\}_{i=1,2,\dots,L,k=1,2,\dots,K}$ 中的每个元素与 F 进行融合,则获取了一组可用于分类的判别向量.

1.5 未知图像分类

当识别未知图像 Y 时,首先需将该图像按步骤(1)对其进行划分,获得 L 个子图像 $y_i (i=1, \dots, L)$. 然后利用第 1.2 节中生成的索引向量 v_i^k 对 y_i 进行采样,获得采样后的特征 y_i^k , 而后再将 y_i^k 投影至 W_i^k 获取融合了全局特征的相关特征 $(y_i^k)^T \times W_i^k$. 最后使用最近邻分类器对 $(y_i^k)^T \times W_i^k$ 进行分类.由于在每个子图像中需进行 K 次采样,因此对第 i 个子图像进行分类,产生 K 个分类结果;而对整个未知图像而言,有 $L \times K$ 个分类结果.出于不同的目的,我们分别对分量分类器采用不同形式的组合方式,如图 2 所示.

- (1) 从提高分量分类器多样性的角度出发,将各分类器采用平行组合方式;
- (2) 从提高子图像分类器性能的角度出发,将各分类器采用层次组合方式.

现定义符号 $d_c^{i,k} \in \{0,1\}$, 当 $d_c^{i,k} = 1$ 时,表示第 i 个子图像的第 k 次采样特征 x_i^k 属于第 c 类; $d_c^{i,k} = 0$ 则表示不属于第 c 类.所以对平行 RS-SpCCA(简称 PRS-SpCCA)结构,其分类结果可表示为

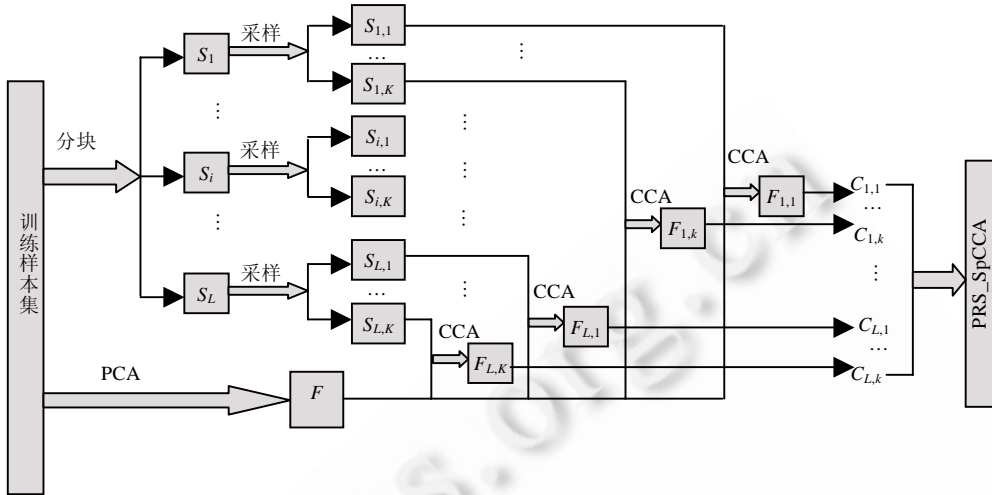
$$Identity(Y) = \arg \max_{1 \leq c \leq C} \left(\sum_{i=1}^L \sum_{k=1}^K d_c^{i,k} \right) \quad (3)$$

而对层次 RS-SpCCA(简称 HRS-SpCCA)结构,实际上执行了两次集成.HRS-SpCCA 首先通过在每个子图像内部进行一次集成(投票方式)来确定相应子图像类别,然后对 L 个子图像类别进行第 2 次组合(同样采用投票方式)以获得最后决策.两次集成(HRS-SpCCA)的结果可表示为

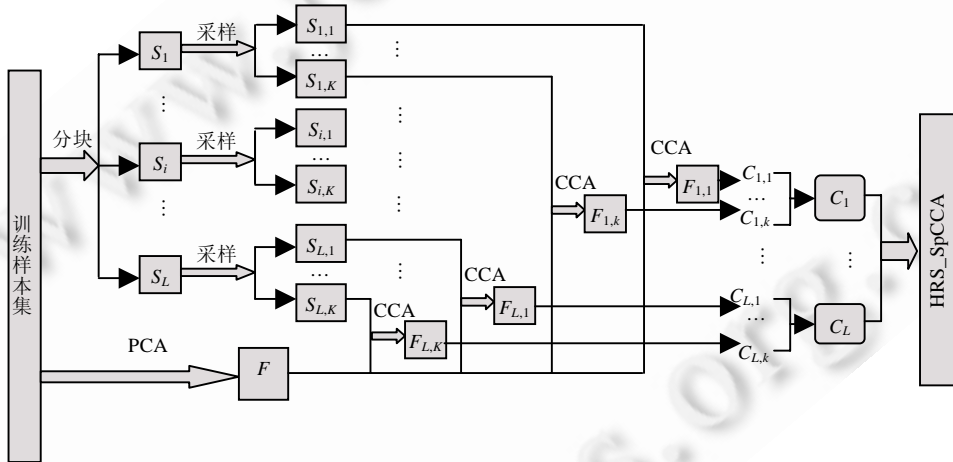
$$Identity(Y) = \arg \max_{1 \leq c \leq C} \sum_{i=1}^L \left(\arg \max_{1 \leq c \leq C} \left(\sum_{k=1}^K d_c^{i,k} \right) \right) \quad (4)$$

由于 RS-SpCCA 能有效提高 SpCCA 分量分类器的精度(详见第 2.4 节)或是提高分量分类器间的多样性(在文献[7]中,我们通过 Kappa 图证实,在子图像中进行随机采样能够有效增加分量分类器的多样性),因此直觉上 RS-SpCCA 能获得比 SpCCA 更好的性能.另外,为更充分利用各分类器间的多样性,采用如图 2(a)所示的平行组合方式将是一个更好的选择.实验结果也表明,PRS-SpCCA 具有比 HRS-SpCCA 更好的识别性能.类似的实验结果(平行结构具有比层次结构更好的识别性能)在文献[7,29]中也获得验证.

RS-SpCCA 对每个子图像集进行特征随机采样,然后将采样的特征子集作为局部特征与全局特征进行融合.显然,当随机采样率为 1 时,并行 RS-SpCCA 和层次 RS-SpCCA 均退化为 SpCCA,因此 SpCCA 只是 RS-SpCCA 的一个特例.



(a) 平行集成结构



(b) 层次集成结构

Fig.2 Structure of RS-SpCCA

图 2 RS-SpCCA 结构图

2 实验结果与分析

为评估 RS_SpCCA 的性能,我们在 AR,Yale,ORL 这 3 个数据集上进行实验.其中,AR 数据集用于测试该方法在时间变化、遮挡等情况下的性能,Yale 用于测试不同训练样本集下 RS_SpCCA 的稳定性,ORL 则用于测试图像有轻微姿态变化情况下的识别能力.


由于文献[19]已对 SpCCA 和 Eigenfaces,Fisherfaces,PCA+CCA,Aw-SpPCA^[12],SpPCA^[8]进行了全面比较,而文献[7]对 Semi-RS 和 M-Eigenfaces^[30],Nitesh'RS^[27]等进行了比较,而且实验证明了 SpCCA 和 Semi-RS 均优于所比方法,所以在该文中,我们仅比较了 RS_SpCCA 与 SpCCA,Semi-RS.实验中,根据文献[19](即 SpCCA)给出的经验结论(子图像大小在原图像大小的 1/100 附近时,可以取得较好效果),我们对每个数据集的子图像大小进行了初步设置(见表 1).而对于两种基于随机采样的 Semi-RS 和 RS-SpCCA,我们设置随机采样率为 0.5,每个子图像集的分类器数设为 20,实验独立执行 10 次,取平均作为最后识别结果.

Table 1 Parameters setting for RS_SpCCA, SpCCA and Semi-RS**表 1** RS_SpCCA, SpCCA 和 Semi-RS 的参数设置

数据集	子图像的大小	随机采样率
AR	6×6	0.5
Yale	4×4	0.5
ORL	4×4	0.5

2.1 在AR数据集上的实验

AR 数据库是一个非常具有挑战性的数据库,它包含 126(76 男,50 女)人超过 3 200 张的正面人脸图像.每个人有 26 幅不同变化的图像,其中,前 13 幅图像在第 1 时期拍摄,而后 13 幅则在两星期后的第 2 个时期拍摄.实验所使用的数据由 Martinez^[31]提供,共包含 100 人(男女各 50)的 2 600 张图像.原人脸图像大小为 165×120,为了计算方便,我们将图像调整为 66×88 大小.图 3 列出了一个人的 26 幅图像.与文献[7,19]中的实验设置一样,选择 Session1 的前 7 个图像作为训练,并将其他的图像根据变化的不同分成了 7 个子集(即 AR77:Session2 的 1~7; AR73Exp:Session2 的 2~4; Illu:Session2 中的 5~7; SungS1:Session1 中的 8~10; Scarf1:Session1 中的 11~13; SungS2:Session2 中的 8~10; Scarf2:Session2 中的 11~13),以分别测试不同变化条件下各种方法的性能.

**Fig.3** All face images for a person in AR database**图 3** AR 数据库中一个人的所有样本

2.1.1 光线和表情的变化

该实验使用 Exp 和 Illu 两个测试集来评估 RS-SpCCA 方法在光线和表情变化时的性能,并与 SpCCA 和 Semi-RS 方法进行比较,实验结果见表 2(最好的结果用加粗显示),从中可见:

- 1) PRS-SpCCA 获得了最好的分类精度,在识别率已经很高的情况下,仍然能至少提高近一个百分点;
- 2) 由于 PRS_SpCCA 更充分的利用了分类器间的多样性,因此 PRS_SpCCA 在整体上优于 HRS-SpCCA,类似的结论在 Semi-RS 方法中也有体现;
- 3) 无论是层次结构还是平行结构,RS-SpCCA 均取得了比相同结构的 Semi-RS 方法更好的性能,这说明融合全局特征是非常有必要的.

Table 2 Recognition accuracies on AR73Exp and AR73Illu testing databases (%)**表 2** 在 AR73Exp 和 AR73Illu 两个测试集上的识别精度 (%)

	SpCCA	PSemi-RS	HSemi-RS	PRS-SpCCA	HRS_SpCCA
Exp	96.67	96.60	95.58	98.90	97.87
Illu	97.33	98.87	96.25	99.70	99.03

2.1.2 图像遮挡

实验以 AR73SungS1, AR73SungS2, AR73Scarf1 和 AR73Scarf2 这 4 个测试集来测试图像有墨镜或围巾等遮挡时,RS-SpCCA 的识别性能.图 4 给出了不同方法的实验结果.从结果中看出,RS-SpCCA 在 4 个测试集中都获得了最好的性能.相对于次优方法(不包括 HRS-SpCCA),最小的提高幅度为 3%,而最大的幅度达到 10%.这些结果充分表明,RS-SpCCA 对严重的遮挡具有更高的鲁棒性.

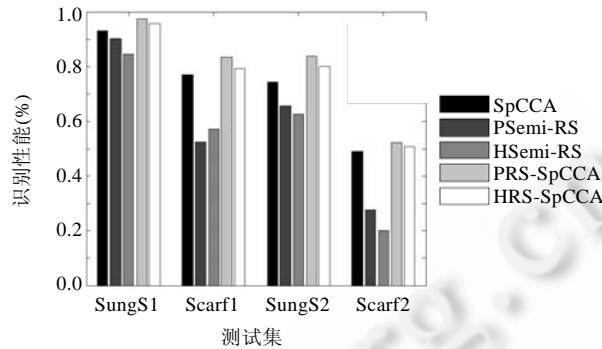


Fig.4 Recognition accuracies on four testing sets

图 4 在 4 个测试集上的识别性能

2.2 在Yale数据集上的实验

Yale 数据库包含 15 个人每人的 11 张灰色图像.全部图像均为正面像,空间位置相对不变,几乎没有任何旋转变化,少数图像有尺度变化,光照强度有少许改变,表情丰富;实验中使用的图像来自于 Cai 处理的数据(www.zjucadcg.cn/dengcai/Data/data.html),图像大小为 32×32 .实验随机地从每类的 11 个样本中选择 n 个数本作为训练,其他的样本作为测试.实验重复进行 20 次,并记录平均值和方差.

实验结果见表 3(最好的结果用加粗显示),表中的数据显示,RS-SpCCA 不仅获得了较好的平均精度,且具有较小的方差.这表明,RS-SpCCA 方法比 SpCCA 和 Semi-RS 具有更稳定的性能.

Table 3 Average and standard deviation on Yale face database (%)

表 3 在 Yale 数据集上的平均精度和方差 (%)

	SpCCA	PSemi-RS	HSemi-RS	PRS_SpCCA	HRS_SpCCA
G6/P5	67.27±4.46	74.51±3.77	72.00±2.51	76.73±2.91	74.18±2.34
G5/P6	61.67±0.57	71.0±2.7	69.3±2.4	72.67±0.59	69.69±2.21

2.3 在ORL数据集上的实验

ORL 人脸数据集包含 400 张来自 40 个人的灰色图像,每人有 10 张不同的图片.该数据集中的一些图像拍摄于不同的时期,且一些图像在人脸表情(睁眼或闭眼)、面部细节(戴眼镜与否)和尺度大小(最大缩放不超过 10%)方面有变化,而且一些图像还有不超过 20 度的旋转.实验所使用的数据同样由 Cai 处理,图像大小为 32×32 .实验随机地从每类样本中选择 n 个样本作为训练,其他的 t 个样本作为测试(用 Gn/Pt 表示)实验重复进行 20 次,并将其平均值作为最后的识别精度,实验结果见表 4(最好的结果用加粗显示).从表中可以看出,无论是 PRS-SpCCA 还是 HRS-SpCCA,对轻微的姿态变化都表现出了较好的性能,相对于其他方法至少提高了一个百分点.但是值得说明的是,当图像有较大的姿态变化时,由于此时所提取的局部特征对正确的识别并不能起太多的作用,因此子图像方法包括 Semi-RS 和 SpCCA 的识别性能,可能会随着姿态变化幅度的增加而下降.

Table 4 Recognition accuracies on ORL face database (%)

表 4 在 ORL 数据集上的识别精度 (%)

	SpCCA	PSemi-RS	HSemi-RS	PRS_SpCCA	HRS_SpCCA
G6/P4	94.37	95.35	93.63	96.75	95.69
G5/P5	92.85	94.50	93.35	96.02	95.20

2.4 讨论

从提高子图像方法中每个分量分类器性能(即构建在子图像上的分类器性能)的角度出发,我们采用层次结

构来组合 $L \times K$ 个分类器.即首先对每个子图像中的 K 个分类器进行组合作为子图像的分类结果,然后再将所有子图像的分类结果进行组合.为说明在子图像中构建多分类器能提高子图像的分类能力,我们分别在 Yale 和 ORL 数据集上进行了比较实验(每类前 6 个样本作训练,其余作测试),并将 HRS-SpCCA 和 SpCCA 进行了比较,结果如图 5 所示.从图中可见,除极个别点之外,经过第 1 次投票后,HRS-SpCCA 子图像的分类能力明显高于 SpCCA 对应的分类能力.又由于各分类器间(子图像之间)多样性基本保持不变,所以 HRS-SpCCA 能获得比 SpCCA 更优的识别性能.另外值得说明的是,在上述实验结果分析中,我们并没有比较 HRS_SpCCA 和 PSemi-RS,其主要原因是两者采用了不同的分类器组合方式,并无可比性.因此,文中在说明 HRS_SpCCA 的良好性能时,并没有同 PSemi-RS 进行比较.

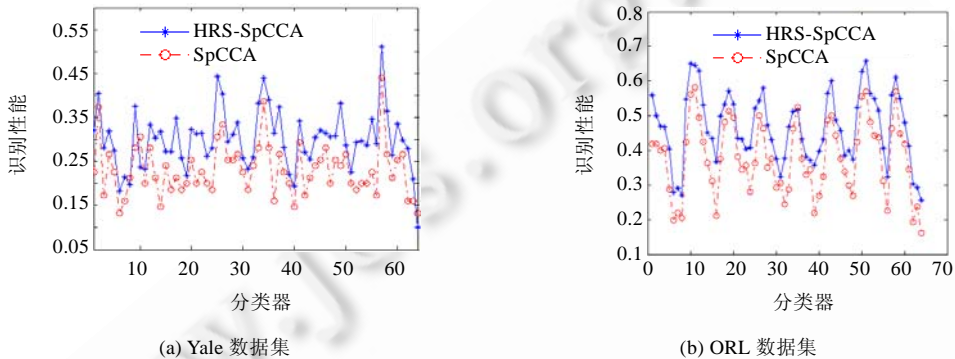


Fig.5 Comparison of base classifiers between SpPCA and HRS-SpCCA

图 5 SpPCA 和 HRS-SpCCA 中各分量分量器的比较

2.5 参数选择

RS-SpCCA 在每个子图像集中执行随机采样,因此,与 SpCCA 相比,RS-SpCCA 增加了随机采样率 r 这一重要参数.这一节,我们将简单讨论采样率 r 对识别性能的影响.实验选择固定的块大小(见表 1),随机采样率从 10% 开始,以 10% 为间隔变化至 100%.图 6 列出了 AR, Yale(6)(每类前 6 个样本作训练,其余作测试)和 ORL(6)等 3 个数据集上随机采样率对 RS-SpCCA 性能的影响.从图中可见:对每个测试集,RS-SpCCA 均在很大范围内获得了比 SpCCA 优越的性能(当 $r=1$ 时,RS-SpCCA 转换为 SpCCA).对 Yale 数据集, r 从 0.2~0.9;对 ORL, r 从 0.3~0.9;而对 AR,也至少在连续的 5 个点上获得了更优的性能.值得说明的是,随机采样率(或随机采样的特征维数)是随机子空间方法所面临的公开问题.虽然我们无从图中获知如何选取最佳的随机采样率,但从结果可知,当随机采样率 r 设置为 0.5~0.9 时,均能获得比 SpCCA 优的识别精度.因此,RS-SpCCA 仍具有可操作性.

子图像大小是子图像方法所面临的公开问题,它决定着子图像方法的性能.在随机采样率为 0.5 的情况下,我们测试了 Yale(6)和 ORL(6)两个数据集不同子图像大小对识别性能的影响.从图 7 中可见:

- 1) 除个别大小(2×2)外,对于其他子图像大小,基于随机采样的 RS-SpCCA 均获得了比 SpCCA 更高的识别性能;
- 2) 相对 SpCCA 而言,RS-SpCCA 受子图像大小变化的影响较小.在 Yale 和 ORL 数据集上,SpCCA 的变化幅度分别为 63% 和 21%;而 RS-SpCCA 只有 22% 和 6.5%.因此,RS-SpCCA 相对来说更稳定,受子图像大小的影响更低.

值得说明的是,当子图像为 2×2 时,RS-SpCCA 进行 50% 采样只能获得两个像素点,无法体现人脸的局部特征,因此效果自然不理想.但从整体上来看,RS-SpCCA 总是能在多个点上获得比 SpCCA 更优的性能.因此,RS-SpCCA 具有一定的操作性.

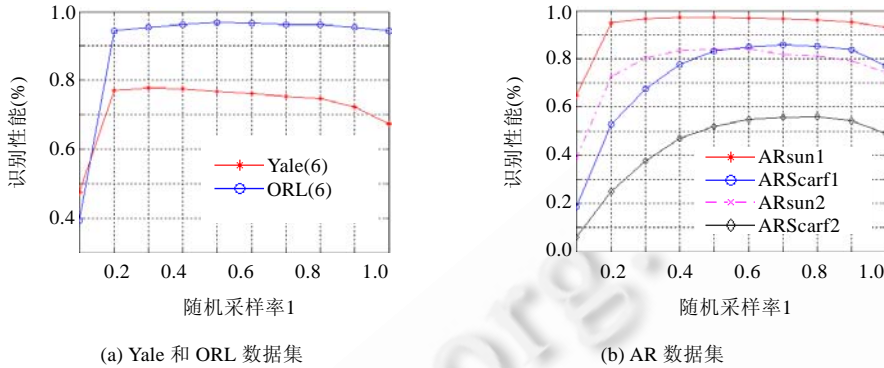


Fig.6 Influences of random sample rate on performance of RS-SpCCA

图 6 随机采样率对 RS-SpCCA 性能的影响




Fig.7 Influences of sub-image size on performance of RS-SpCCA and SpCCA

图 7 子图像大小对 RS-SpCCA 和 SpCCA 的影响

2.6 运算效率

算法的运算效率是衡量算法优劣的一项重要指标.提出的 RS-SpCCA 方法通过在每个子图像集中进行随机采样,构建了更多的分量分类器,因此相对于 SpCCA 和 Semi-RS 方法而言,RS-SpCCA 在训练阶段和测试阶段有较高的时间复杂度.设原始样本维数为 D ,训练集样本个数为 N ,子图像维数为 d (通常, $D \gg N > d$),每个子图像集的分类器数目为 K ,随机采样率为 $r(r \leq 1)$,块数为 p (在本文中,有等式 $D = d \times p$ 成立),则各算法关键步骤的时间复杂度及总体时间复杂度见表 5.很明显,RS-SpCCA 在训练阶段的时间复杂度均高于 SpCCA 和 Semi-RS;而在测试阶段,RS-SpCCA 具有和 Semi-RS 完全相同的时间复杂度(实际上,RS-SpCCA 和 Semi-RS 具有完全相同的测试过程).

Table 5 Time complexities for SpCCA, RS-SpCCA and Semi-RS

表 5 SpCCA, RS-SpCCA 和 Semi-RS 算法的时间复杂度

	训练阶段				测试阶段			
	全局特征获取(PCA)	局部特征获取	全局和局部信息融合	总体时间复杂度	相关/采样特征获取	相似度计算	投票决策	总体时间复杂度
SpCCA	$O(N^3)$	$O(D)$	$O(pN^3)$	$O(pN^3+D)$	$O(Dd)$	$O(DN)$	$O(p)$	$O(Dd+DN+p)$
RS-SpCCA	$O(N^3)$	$O(D)$	$O(KpN^3)$	$O(KpN^3+D)$	$O(KDdr^2)$	$O(KDNr)$	$O(Kp)$	$O(KDdr^2+KDNr+Kp)$
Semi-RS	—	$O(pd^3)$	—	$O(pd^3)$	$O(KDdr^2)$	$O(KDNr)$	$O(Kp)$	$O(KDdr^2+KDNr+Kp)$

然而算法的训练过程是一次性完成的,并不需要重复操作.因此,这里我们将重点考虑测试时间.RS-SpCCA 的测试时间主要由以下部分组成:(a) 相关特征获取时间;(b) 测试样本与训练样本的相似度计算时间;(c) 最后分类结果的决策时间.从表 5 可以看出,对于大规模的人脸识别来说,系统速度的瓶颈在于相似度计算.由于 RS-SpCCA 构建了比 SpCCA 更多的分类器,需要进行更多次的相似度运算和比较,因此为了加快测试速度,我们采用由粗到精的分类策略^[1].首先使用全局特征构建分类器,根据该分类器求出测试样本与训练样本集中所有样本之间的相似度并进行排序,保留一定数目(设其个数为 M)与测试样本差异较小的样本,然后将测试样本在局部特征分类器中的比较限定在这 M 个训练样本中.由于减少了相似度计算的次数,从而提高了测试效率.理论上, M 越大,最后的性能越优,但消耗时间也越多; M 越小,消耗时间越少,但性能也会有所下降.由图 8 可见(使用 AR77 作为测试集),当使用全局分类器(eigenfaces)所保留的候选图像数量 $M < 150$ 时,系统的识别率开始显著下降.因此,为了保证系统一定的精度,我们选择 $M=150$ 为理想值.同时,我们给出了当 $M=150$ 时,优化后的 RS-SpCCA 算法在测试阶段所需的时间,并与 SpCCA 方法进行了比较(Matlab 7.0, 双核 2.0G, 1G 内存).从表 6 中可以看出,采用由粗到精的机制不仅大大地提高了 RS-SpCCA 的运算效率,而且具有比 SpCCA 更快的运算速度.由于在理想候选样本数下,RS-SpCCA 的识别精度能保持相对不变,因此由粗到精机制是有效的.值得说明的是,表 6 所示的测试时间是在多个测试样本串行输入情况下的整体测试时间,如果采用并行输入形式,利用 Matlab 的编程技巧可降低整体的测试时间.另外,作为并行多分类器系统,我们自然可采用并行处理以进一步降低 RS-SpCCA 的测试时间.




Fig.8 Effect of number of candidate sample on recognition accuracies

图 8 候选样本数 M 对识别性能的影响

Table 6 Testing time for SpCCA, RS-SpCCA and Semi-RS(s)

表 6 SpCCA, RS-SpCCA 和 Semi-RS 算法测试时间比较(s)

	SpCCA	RS-SpCCA	由粗到精的 RS-SpCCA
AR77	1 267	9 648	483

3 结束语

本文针对目前子图像方法所存在的两点不足:1) 分类器数目受子图像划分的影响;2) 对局部特征间关系的忽略和对全局信息的欠利用,提出了基于特征采样和特征融合的子图像方法(RS-SpCCA).

通过特征采样,增加了分类器的数目,提高了分量分类间的多样性;通过特征融合,达到对全局信息及全局与局部间关系的充分利用.在 3 个标准人脸数据集上的实验表明,RS-SpCCA 具有比单纯特征采样方法(Semi-RS)和特征融合方法(SpCCA)更优的性能.

尽管在文中 RS-SpCCA 使用 PCA 提取全局特征,使用子图像原始特征的采样特征集作为局部特征.但实际操作中,可以采用其他方法(如离散傅里叶变换等)提取的全局特征替换 PCA 特征或对子图像的采样特征进行

适当处理(如,为充分利用类别信息,使用 LDA 进行特征提取)以获取更优的性能.另外,RS-SpCCA 仅使用了局部相关特征来作为判别特征而丢弃了全局特征.同时,利用 CCA 的全局相关特征和局部相关特征将进一步提高算法的性能.

References:

- [1] Su Y, Shan SG, Chen LX, Gao W. Integration of global and local feature for face recognition. *Journal of Software*, 2010,21(8): 1849–1862 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3627.htm> [doi: 10.3724/SP.J.1001.2010.03627]
- [2] Su Y, Shan SG, Chen LX, Gao W. Hierarchical ensemble of global and local classifiers for face recognition. *IEEE Trans. on Image Processing*, 2009,18(8):1885–1896. [doi: 10.1109/TIP.2009.2021737]
- [3] Turk M, Pentand A. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 1991,3(1):71–86. [doi: 10.1162/jocn.1991.3.1.71]
- [4] Belhumeur PN, Hespanha JP, Kriegman DJ. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1997,19(7):711–720. [doi: 10.1109/34.598228]
- [5] Zhen L, Liao SC, Pietikainen M, Li SZ. Face recognition by exploring information jointly in space, scale and orientation. *IEEE Trans. on Image Processing*, 2011,20(1):247–256. [doi: 10.1109/TIP.2010.2060207]
- [6] Tan XY, Bill T. Enhanced local texture feature sets for face recognition under difficult lighting conditions. *IEEE Trans. on Image Processing*, 2010,19(6):1635–1650. [doi: 10.1109/TIP.2010.2042645]
- [7] Zhu YL, Liu J, Chen SC. Semi-Random subspace method for face recognition. *Image and Vision Computing*, 2009,27(9): 1358–1370. [doi: 10.1016/j.imavis.2008.12.009]
- [8] Chen SC, Zhu YL. Subpattern-Based principle base analysis. *Pattern Recognition*, 2004,37(5):1081–1083. [doi: 10.1016/j.patcog.2003.09.004]
- [9] Zhu YL. Sub-Pattern non-negative matrix factorization based on random subspace for face recognition. In: *Proc. of the Int'l Conf. on Wavelet Analysis and Pattern Recognition*. 2007. 1356–1360. [doi: 10.1109/ICWAPR.2007.4421645]
- [10] He XF, Niyogi P. Locality preseving projections. In: *Advances in Neural Information Processing Systems*. 2003.
- [11] Gottumukkal R, Asari VK. An improved face recognition technique based on modular PCA approach. *Pattern Recognition Letters*, 2004,25(4):429–436. [doi: 10.1016/j.patrec.2003.11.005]
- [12] Tan KR, Chen SC. Adaptively weighted sub-pattern PCA for face recognition. *Neurocomputing*, 2004,64:505–511.
- [13] Nabatchian A, Raheem EA, Ahmadi M. Illumination invariant feature extraction and mutual-information-based local matching for recognition under illumination variation. *Pattern Recognition*, 2011,44(10-11):2576–2587. [doi: 10.1016/j.patcog.2011.03.012]
- [14] Wang JZ, Zhang BX, Wang SY, Qi M, Kong J. An adaptively weighted sub-pattern locality preserving projection for face recognition. *Journal of Network and Computer Applications*, 2010,33(3):323–332. [doi: 10.1016/j.jnca.2009.12.013]
- [15] Kanan HR, Faez K. Recognizing faces using adaptively weighted sub-gabor array from a single sample image per enrolled subject. *Image and Vision Computing*, 2010,28(3):438–448. [doi: 10.1016/j.imavis.2009.06.013]
- [16] Kumar VK, Negi A. SubXPCA and a generalized feature partitioning approach to principal component analysis. *Pattern Recognition*, 2008,41(4):1398–1409. [doi: 10.1016/j.patcog.2007.08.006]
- [17] Hsieh PC, Tung PC. A novel hybrid approach based on sub-pattern technique and whiten PCA for face recognition. *Pattern Recognition*, 2009,42(5):978–984. [doi: 10.1016/j.patcog.2008.09.024]
- [18] Zhang WC. Research on local Gabor binary patterns (LGBP) for face representation and recognition [Ph.D. Thesis]. Harbin: Harbin University of Technology, 2003 (in Chinese with English abstract).
- [19] Hong Q, Chen SC, Ni XL. Sub-Pattern canonical correlation analysis with application in face recognition. *ACTA AUTOMATICA SINICA*, 2008,34(1):21–30 (in Chinese with English abstract).
- [20] Penev PS, Atick JJ. Local feature analysis: A general statistical theory for object representation. *Network: Computation in Neural Systems*, 1996,7(3):477–500. [doi: 10.1088/0954-898X/7/3/002]
- [21] Liu ZM, Liu CJ. Fusion of color, local spatial and global frequency information for face recognition. *Pattern Recognition*, 2010, 43(8):2882–2890. [doi: 10.1016/j.patcog.2010.03.003]
- [22] Hotelling H. Relations between two sets of variates. *Biometrika*, 1936,28(3-4):321–377.

- [23] Ho TK. The random subspace method for constructing decision forests. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1998,20(8):832–844. [doi: 10.1109/34.709601]
- [24] Wang XG, Tang XO. Random sampling for subspace face recognition. *Int'l Journal of Computer Vision*, 2006,70(11):91–104. [doi: 10.1007/s11263-006-8098-z]
- [25] Zhang XY, Jia YD. A linear discriminant analysis framework based on random subspace for face recognition. *Pattern Recognition*, 2007,40(9):2585–2591. [doi: 10.1016/j.patcog.2006.12.002]
- [26] Wang XG, Tang XO. Random sampling LDA for face recognition. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. IEEE Computer Society Press, 2004. 259–265. [doi: 10.1109/CVPR.2004.1315172]
- [27] Chawla NV, Bowyer KW. Random subspaces and subsampling for 2-D face recognition. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. IEEE Computer Society Press, 2005. 582–589. [doi: 10.1109/CVPR.2005.286]
- [28] Zou J, Ji Q, Nagy G. A comparative study of local matching approach for face recognition. *IEEE Trans. on Image Processing*, 2007, 16(10):2617–2628. [doi: 10.1109/TIP.2007.904421]
- [29] Tao DC, Tang XO. Asymmetric bagging and random subspace for support vector machines-based relevance feedback in image retrieval. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2006,28(7):1088–1098. [doi: 10.1109/TPAMI.2006.134]
- [30] Pentand A, Moghaddam B, Starner T. View-Based and modular eigenspaces for face recognition. In: *Proc. of the IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*. IEEE Computer Society Press, 1994. 84–91. [doi: 10.1109/CVPR.1994.323814]
- [31] Martinez AM, Benavente R. The AR face database. Technical Report, Computer Vision Center (CVC), 1998.

附中文参考文献:

- [1] 苏煜,山世光,陈熙霖,高文.基于全局和局部特征集成的人脸识别.软件学报,2010,21(8):1849–1862. <http://www.jos.org.cn/1000-9825/3627.htm> [doi: 10.3724/SP.J.1001.2010.03627]
- [18] 张文超.局部 Gabor 二值模式人脸表示与识别方法研究[博士学位论文].哈尔滨:哈尔滨工业大学,2007.
- [19] 洪泉,陈松灿,倪雪蕾.子模式典型相关分析及其在人脸识别中的应用.自动化学报,2008,34(1):21–30.



朱玉莲(1978—),女,山东聊城人,博士,副教授,主要研究领域为模式识别.



陈松灿(1962—),男,博士,教授,博士生导师,主要研究领域为神经计算,模式识别,图像处理与分析,核方法及其应用,数据挖掘.