

子模式典型相关分析及其在人脸识别中的应用

洪泉¹ 陈松灿¹ 倪雪蕾¹

摘要 传统的典型相关分析 (CCA) 是有效的特征提取方法之一, 已广泛应用于包括人脸识别在内的模式识别的许多领域. 但在人脸识别为代表的高维小样本问题上该方法存在如下不足: 1) 人脸识别的小样本特性使 CCA 两组特征矢量构成的总体协方差矩阵奇异, 难以直接应用; 2) 作为一种全局线性投影方法, 不足以很好地描述非线性的人脸识别问题; 3) 缺乏对局部变化的识别鲁棒性. 本文受已提出的子模式主分量分析 (SpPCA) 的启发, 提出了子模式典型相关分析 (SpCCA). 该方法将局部与全局特征矢量之间的相关性特征作为有效的判别信息, 既达到了融合局部与全局信息的目的, 又消除了特征之间的信息冗余. 通过子模式的划分, SpCCA 避免了小样本问题, 更好地描述了非线性的人脸识别问题; 并通过投票方式融合结果, 增强了对局部变化的鲁棒性. 在 AR 与 Yale 两个人脸数据集上的实验证实了该方法比对比方法不仅有更优的识别性能, 而且更加稳定和鲁棒.

关键词 典型相关分析 (CCA), 子模式主分量分析 (SpPCA), 子模式典型相关分析 (SpCCA), 小样本问题, 人脸识别
中图分类号 TP391

Sub-pattern Canonical Correlation Analysis with Application in Face Recognition

HONG Quan¹ CHEN Song-Can¹ NI Xue-Lei¹

Abstract Canonical correlation analysis (CCA) is a classic feature extraction method and is widely applied in pattern recognition. But in face recognition and other small sample size (SSS) problem, its typical disadvantages are: 1) CCA fails, if directly applied, due to the singularity of the covariance matrices of its two groups of features caused by the SSS problem; 2) it can not describe the nonlinear face recognition problem well, for its globally linear property in nature; 3) it is short of the robustness to local variants. Enlightened by our previous sub-pattern PCA (SpPCA) we present sub-pattern canonical correlation analysis (SpCCA) in this paper. By maximizing the correlation between the local and global features of the original samples, this method can not only fuse local and global features well but also eliminate the redundant information among the features. By combining with the sub-pattern method, SpCCA avoids the SSS problem, realizes the formulation for the nonlinear face recognition problem better, and enhances the robustness to the local variants by voting. Experiments on AR and Yale face databases show that the proposed method is stable, robust, and effective.

Key words Canonical correlation analysis (CCA), sub-pattern PCA (SpPCA), sub-pattern CCA (SpCCA), small sample size (SSS), face recognition

特征提取是模式识别的重要组成部分, 通常仅能获得一组目标的一组数据, 该组数据形成了被称之为单模的原始特征数据, 而从一组目标中获得的多组数据则形成了被称之为多模的原始特征数据. 单模的特征提取方法有主分量分析 (Principal component analysis, PCA)^[1]、线性判别分析 (Linear discriminant analysis, LDA)^[2] 等. 它们已被广泛应用于人脸识别. 典型相关分析 (Canonical correlation analysis, CCA)^[3] 作为一种多模的特征提取方法, 在单模的模式识别问题中未被广泛重视, 可能归咎于仅拥有单模数据, 这对 CCA 的应用带来了

一定的困难. Sun 等在文献 [4–6] 中研究了这个问题, 通过从单模数据建立多模数据, 使 CCA 能够应用于人脸识别等领域.

然而, 一方面 CCA 与 LDA 一样面临着人脸识别中的小样本问题, 幸运的是对 LDA 中的此问题已有很多深入的研究^[7], 典型的解决办法是先用某种方法将原样本预降至适当低的维数以避免小样本问题出现, 而后可用 LDA 方法, 如 PCA + LDA (Fisher face)^[2] 即是其中非常有效的方法之一; 最近所提出的判别公共向量 DCV^[8–9] 方法则更有效地对 LDA 的小样本问题进行了求解, 使之取得了较 PCA + LDA 更好的效果. 我们自然也可以使用类似的方法来解决 CCA 的小样本问题, 如 PCA + CCA^[5] 方法等. 但本文中, 我们将采用另一方法来解决这一问题.

另一方面 CCA 与 PCA、LDA 等均属于全局方法, 忽略了对局部信息的利用, 因而存在对局部变化 (如遮挡等) 敏感的问题. 为克服此问题, 通常可使用鲁棒度量和子模式化等方法. 采用鲁棒度量的方法求

收稿日期 2006-07-19 收修改稿日期 2007-03-28
Received July 19, 2006; in revised form March 28, 2007
国家自然科学基金 (60473035), 江苏省自然科学基金 (BK2005122) 资助

Supported by National Natural Science Foundation of China (60473035), Natural Science Foundation of Jiangsu Province of China (BK2005122)

1. 南京航空航天大学信息科学与技术学院 南京 210016
1. School of Information Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016
DOI: 10.3724/SP.J.1004.2008.00021

解一般较复杂, 计算代价较高; 而将原模式划分成子模式后分别处理, 不仅可避免在 LDA 与 CCA 中所出现的小样本问题, 而且可使局部变化仅限制在局部范围, 由此达成鲁棒的识别, 同时此方法的复杂性也比较低。

Sun 等人只是将 CCA 应用于人脸识别, 并未解决 CCA 的小样本与鲁棒性缺乏的问题。因此, 基于我们原来提出的子模式 PCA (Sub-pattern PCA, SpPCA)^[10], 同时尝试采用与 Sun 等人对 CCA 不同的多模构建方式, 本文将子模式方法结合到 CCA 之中, 融合局部与全局信息, 解决 CCA 在人脸识别等问题中存在的小样本、忽略局部信息以及对局部变化缺乏鲁棒性的问题。

在以往的工作中, 为了使 PCA 不仅能利用全局信息, 而且能利用局部信息, 我们提出了 SpPCA^[10]。该方法首先将原向量模式不重叠地等分为多个子模式, 将原模式中对对应位置的子模块分别组成一子模式训练集, 然后对每个子模式训练集单独使用 PCA 提取特征, 最后将这些所提取的特征拼接成一个全局特征向量用于分类。该方法充分利用了局部信息, 保留了子模块之间的空间关系。但最后一步的全局特征组合方式仍然导致该方法的非鲁棒性。为此, Tan 等人提出了用于人脸识别的自适应加权子模式 PCA (Aw-SpPCA)^[11], 将 SpPCA 最后一步的“拼接子特征作为全局特征”修改为单独使用每一组子特征进行分类, 然后用多组分类结果加权投票得到最终的分类结果。这样抑制了每个子块对全局的影响, 使每个子块的效果被限制在该子块内部, 对全局的影响都为 $1/L$ (L 为子块数), 即使某子块有严重的光照、表情、遮挡等变化, 该子块对整体判断带来的误差也最多为 $1/L$ (或者若仍然分类正确, 则误差为 0; 若分类错误, 则误差为 $1/L$), 这极大地提高了对局部变化的鲁棒性。但由于该方法仍以局部为基础的基于投票决策的分类, 丢失了局部之间的许多重要的全局信息, 导致其在分类效果上有所欠缺。

受到 SpPCA 及 Aw-SpPCA 的启发, 本文提出了适用于高维问题的子模式典型相关分析 (SpCCA) 方法, 并将其运用于人脸识别。该方法通过典型相关分析 (CCA) 融合局部与全局信息, 其第一步将局部与全局特征矢量之间的相关性特征作为有效的判别信息, 既达到了融合局部与全局信息的目的, 又消除了特征之间的信息冗余, 在较低的代价上同时实现了以上两种特征提取的优点; 第二步使用投票方式进行最终分类, 使该方法对局部变化的识别具有鲁棒性, 从而使其在分类精度上获得改进。同时该方法解决了当两组特征矢量构成的总体协方差矩阵奇异时, 典型投影矢量集的求解问题, 使之适合于高维小样本的情形, 推广了典型相关分析

的适用范围。

本文内容安排如下: 第 1 节详细介绍算法; 第 2 节的实验将在两个标准人脸数据集上研究参数选取问题, 并比较 DCV、PCA + CCA、SpPCA、Aw-SpPCA 和 SpCCA; 第 3 节对本文内容进行总结。

1 SpCCA 算法

SpCCA 算法主要分为四步:

- 1) 将人脸图像划分为子模块, 作为 CCA 融合的局部特征矢量;
- 2) 提取原人脸图像的整体特征, 作为 CCA 融合的全局特征矢量;
- 3) 使用 CCA 融合 1) 中的局部特征与 2) 中提取的全局特征;
- 4) 分类未知图像。

1.1 局部特征提取

局部特征的提取有许多种方法, 本文仅使用简单的图像划分方法。图像可以按其内容特征划分, 如对面脸图像按额头、眼睛、鼻子嘴巴划分; 也可以按灰度级划分, 将类似范围的灰度的点集合在一起; 还可以直接使用简单的几何图形分割原图像。本文使用最简单的矩形分割原图像, 其使用简便, 且很好地保留了原图像的空间信息。实验使用了重叠与不重叠两种划分方式。第一种将每幅人脸图像按统一规格不重叠地等分为多幅子图像, 作为 CCA 融合的局部信息 (本文将在第 1.3 节详细介绍 CCA 融合特征的过程)。

设训练集 $Tr = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)_{W_1 W_2 \times N}$ 为 C 个人的 N 张大小为 $W_1 \times W_2$ 的人脸图像。每张图像被不重叠地等分为 L 张子图像, 每个子图像矩阵被重新组合为 $m = W_1 \times W_2 / L$ 维的列向量, 然后分别将所有处于原图像中相同位置的子图像所组合成的那些列向量放在一起组成 L 个独立的子模式集合 $T_r^1, T_r^2, \dots, T_r^L$ 。该过程详见图 1 (见下页)。

对子块大小 m 的选取需满足一定条件。首先 m 应满足

$$m \leq N - C \quad (1)$$

这保证了 CCA 第一组特征矢量构成的总体协方差矩阵非奇异。 m 在满足式 (1) 约束的条件下, 仍有很大的选择空间, 注意到 m 选取过小会过于注重局部, 而忽略了各个局部之间的联系, 从而导致分类效果不佳; 过大则会趋近于整体方法, 导致一方面会忽略很多局部信息, 另一方面易使局部变化的影响扩展到整体, 效果也不理想。本文实验部分给出了选取 m 的一些参考方法。

不重叠地划分图像会分割各个子图之间的联系, 并导致完全忽略子模式之间的关系。因此, 我们也尝

试了重叠划分方式, 如图 2 所示.

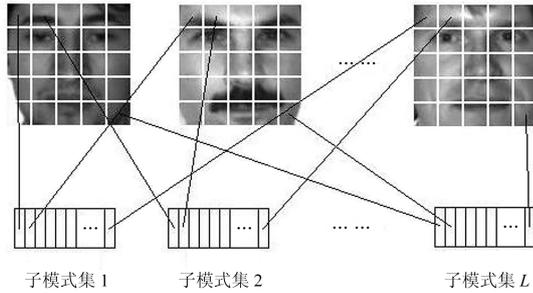


图 1 子模式人脸图像集构建示意图
(图像取自 Yale 人脸数据集^[12])

Fig. 1 The way of constituting sub-pattern face image set (Images are from Yale face database^[12])

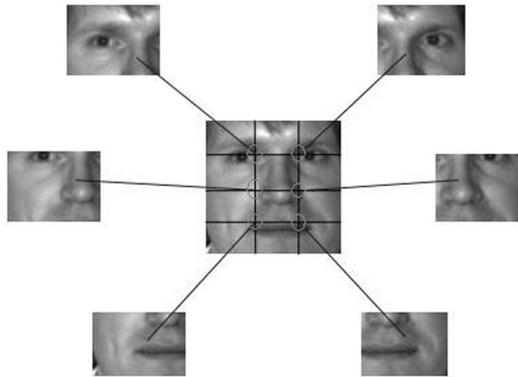


图 2 重叠子模式人脸图像集构建示意图
(图像取自 Yale 人脸数据集^[12])

Fig. 2 The way of constituting overlapped sub-pattern face image set (Images are from Yale face database^[12])

这种划分使原来虽相邻但又相互隔绝的两个不同子块可以联系起来, 从而使所提取的信息会更加充分.

当然, 该划分也存在两个问题: 1) 在图像边缘的点比图像中间的点使用次数少, 从而所占权重小. 不过当划分很小, 如后面实验中的 6×6 , 5×5 时, 边缘未被重叠的像素只有 $2 \sim 3$ 个, 且边缘像素一般重要度都较低, 对全局并不会造成大的影响. 2) 当重叠划分后, 分块数会急剧上升, 如果水平与垂直各重叠 50%, 则分块数会增多为原来的 4 倍, 使计算量急剧上升. 然而随着计算机速度的飞速增长与存储器容量的快速上升, 现在几千维的人脸识别问题已经可以在很短的时间内完成, 我们更加关注的是识别率的问题, 因此牺牲一点速度与存储容量换取识别率是值得的. 这样, 我们就可以根据实际需要调整重叠

量的大小, 以平衡速度与识别率.

1.2 整体特征提取

在模式识别领域中, 有许多经典的整体特征提取方法, 如 PCA、LDA、小波变换以及在 CCA 中应用广泛的硬标号^[13](即 one of c 编码) 等, 它们各有特色, 在各自的领域中都有广泛的应用. 我们测试了 PCA、LDA、db 小波变换^[14] 和硬标号四种整体特征, 其中 PCA 比硬标号略好, 两者优于 LDA 与小波变换. 由于使用硬标号效果不明显, 且相当于引入类信息, 为了与无类信息的 DCV、PCA + CCA、SpPCA、Aw-SpPCA 方法比较时的公平性, 本文实验均采用 PCA 作为整体特征提取方法. 实际应用该方法时, 如果找到更合适的整体特征提取方法或有特殊需要, 只需替换 CCA 的第二组特征矢量即可.

对训练集 Tr 使用 PCA 进行特征提取, 可得投影矩阵 W_{PCA} , 将 Tr 中样本使用 W_{PCA} 投影, 可得一组低维特征 $Tr_y = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N)_{m2 \times N}$.

在提取整体信息时需注意所提取的整体信息的维数与局部信息一样应受到限制, 满足全局信息的维数

$$m2 \leq N - C \quad (2)$$

这保证了 CCA 第二组特征矢量构成的总体协方差矩阵非奇异. 这样 CCA 的两组特征矢量构成的总体协方差矩阵均非奇异, 从而解决了其小样本问题.

1.3 CCA 特征融合

对每个训练集对 (Tr^i, Tr_y) 分别用 CCA 进行融合.

由第 1.1 节得 L 个独立的子训练集 Tr^1, Tr^2, \dots, Tr^L , 每个子训练集 Tr^i ($i = 1, 2, \dots, L$) 有 N 个样本, C 个类别, 样本维数为 m , 即有 $Tr^i = (\mathbf{x}_1^i, \mathbf{x}_2^i, \dots, \mathbf{x}_N^i)_{m \times N}$, 且有第 1.2 节的 $Tr_y = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N)_{m2 \times N}$.

以 (Tr^i, Tr_y) 为训练集对构造 CCA 投影矩阵对 (W_x^i, W_y^i) , 要求通过该投影矩阵对对原样本对进行投影后所得的两组低维特征之间具有最大的相关性, 且两组低维特征的各分量之间不相关. 这样我们可以提取出同一样本在不同表示模式下的本质特征, 而忽略由于表示模式不同所产生的一些冗余特征, 去除不同表示模式中的相同特征, 从而在提高识别率的同时也改善了计算复杂度.

定义第一组特征矢量 Tr^i 的协方差矩阵 $S_{xx}^i = E[\mathbf{x}\mathbf{x}^T]$, 第二组特征矢量 Tr_y 的协方差矩阵 $S_{yy} = E[\mathbf{y}\mathbf{y}^T]$, 它们之间的互协方差矩阵为 $S_{xy}^i = E[\mathbf{x}\mathbf{y}^T]$,

则最佳投影矩阵定义为

$$[W_x^i, W_y^i]_{opt} = [(w_{x1}^i \ w_{x2}^i \ \cdots \ w_{xr}^i), (w_{y1}^i \ w_{y2}^i \ \cdots \ w_{yr}^i)] = \arg \max_{w_{xk}^i, w_{yk}^i} \frac{w_{xk}^i \text{T} S_{xy}^i w_{yk}^i}{\sqrt{w_{xk}^i \text{T} S_{xx}^i w_{xk}^i \cdot w_{yk}^i \text{T} S_{yy}^i w_{yk}^i}}, 1 \leq r \leq C-1 \quad (3)$$

满足

$$\begin{cases} w_{xk}^i \text{T} S_{xx}^i w_{xk}^i = w_{yk}^i \text{T} S_{yy}^i w_{yk}^i = 1, \\ w_{xk}^i \text{T} S_{xx}^i w_{xj}^i = w_{yk}^i \text{T} S_{yy}^i w_{yj}^i = 0, \\ j, k = 1, 2, \dots, r, k \neq j \\ w_{xk}^i \in \mathbf{R}^m, w_{yj}^i \in \mathbf{R}^{m2} \end{cases} \quad (4)$$

由 CCA 方法可知 W_x^i, W_y^i 满足

$$\begin{cases} S_{xy}^i S_{yy}^{-1} S_{yx}^i W_x^i = S_{xx}^i W_x^i \Lambda^i \\ S_{yx}^i (S_{xx}^i)^{-1} S_{xy}^i W_y^i = S_{yy}^i W_y^i \Lambda^i \end{cases} \quad (5)$$

其中, Λ^i 是广义特征值问题 (5) 的前 r 个最大的非负特征值按降序组成的对角矩阵, W_x^i 与 W_y^i 的列为这些特征值所对应的特征向量, 且满足式 (4) 约束.

对所有子训练集 Tr^1, Tr^2, \dots, Tr^L 与 Tr_y 分别如上构造 CCA 投影矩阵, 则可得一组用于特征提取的投影矩阵对 $(W_x^1, W_y^1), (W_x^2, W_y^2), \dots, (W_x^L, W_y^L)$. 由于 CCA 的第一组特征向量为各个局部的特征, 第二组特征向量用的是全局特征, 经过 CCA 投影后, 第一组特征的 L 个向量中的每一个向量变为以某块的局部特征为主, 融合了整体特征; 第二组特征的 L 个向量中的每一个向量变为以全局特征为主, 融合了某块的局部特征. 由于在下面的分类过程中, 还需要通过投票方式组合 L 个子块的结果, 如果使用第二组特征则会过于偏重全局特征, 从而丧失了部分子模式方法对局部变化的鲁棒性, 因此我们仅取第一组特征的投影向量作为判别向量. 实验第一部分的实验 3 将给出仅使用第一组特征、仅使用第二组特征以及共同使用两组特征比较.

1.4 分类

分类算法使用最近邻方法^[15].

设 Y 为未知人脸图像, 将其按第 1.1 节中同样的方式划分为 L 个子图像, 然后重组为列向量模式, 得到 L 个子样本 y^1, y^2, \dots, y^L .

定义两子样本 x_k^i, y^i 之间的相似度为

$$\text{Similarity}(x_k^i, y^i) = -(x_k^i - y^i) \text{T} W_x^i (W_x^i)^{\text{T}} (x_k^i - y^i) \quad (6)$$

首先计算未知人脸第 i 个子样本 y^i 与其对应的子训练集 Tr_r^i 中各样本的相似度, 选取其中最大相似度对应 Tr_r^i 中子样本的标号作为 y^i 的标号: 即未知人脸第 i 个子样本的分类结果, 这样 L 个独立的子模式可以得到 L 个独立的分类结果.

未知图像 Y 被分入第 k 类的概率定义为

$$T_k = \frac{1}{L} \sum_{i=1}^L d_k^i \quad (7)$$

其中 $d_k^i = \begin{cases} 0 & \text{第 } i \text{ 个子图像未被分入第 } k \text{ 类} \\ 1 & \text{第 } i \text{ 个子图像被分入第 } k \text{ 类} \end{cases}$

则未知图像 Y 的分类结果为

$$\text{Identity}(Y) = \arg \max_{1 \leq k \leq C} (T_k) \quad (8)$$

2 实验结果

2.1 人脸图像数据集

我们在两个标准人脸数据集上进行了实验: AR 人脸数据集^[16] 和 Yale 人脸数据集^[12].

在 AR 人脸数据集中选取了 100 个人 (50 个男性, 50 个女性) 进行实验, 每人 26 张图像. 如图 3 所示, 每个人的 26 张图像分为 2 个时期: Session 1 和 Session 2, 两者采集时间间隔 2 周, 每个 Session 的图像按变化不同归为不同组, 第 1 张是正面无表情均匀光照图像, 第 2~4 张为表情变化图像, 第 5~7 张为光照方向变化图像, 第 8~10 张为墨镜遮挡图像, 第 11~13 张为围巾遮挡图像.

在 Yale 人脸数据集中选取了 15 个人, 每人 11 张图像. 图像有一定的面部表情差异和光照条件变化, 部分图像有眼镜遮挡.



图 3 AR 人脸数据^[16] 示意图

Fig. 3 Some image samples of AR faces database^[16]

在预处理步骤中, 首先将 AR 图像灰度化, 然后 AR 与 Yale 图像分别经旋转使眼睛水平, 并裁剪至 66×48 及 50×50 大小. 图 1、2 中列举了部分 Yale 图像, 图 3 中列举了部分 AR 图像.

AR 数据集实验数据分组情况见表 1. 为了实验能够被精确重现, Yale 数据集上与 Aw-SpPCA^[11] 文中一样采用留一法进行实验, 计算 11 轮, 每次选取 1 个样本做测试, 其余 10 个做训练. Yale 数据集每人有 11 幅图像, 每轮选取的时候, 分别留下不同的样本做测试, 其余做训练, 然后将 11 轮的结果取平均作为最终结果.

表 1 AR 数据分组
Table 1 Grouping of AR database

数据分组名称	训练样本	测试样本
AR77		Session 2 的 1~7 张
AR73Exp		Session 2 的 2~4 张
AR73Illu	Session 1	Session 2 的 5~7 张
AR73SungS1	的	Session 1 的 8~10 张
AR73SungS2	1~7 张	Session 2 的 8~10 张
AR73ScarfS1		Session 1 的 11~13 张
AR73ScarfS2		Session 2 的 11~13 张

2.2 实验参数选取及结果表示

使用作为整体方法代表的 PCA + LDA 与 PCA + CCA 方法时, PCA 降至的维数以使 PCA + LDA 及 PCA + CCA 方法达到最高的识别率为准, 如图 4 中 PCA 430 + CCA 就代表先 PCA 降至 430 维, 然后 CCA.

使用 SpPCA 及 Aw-SpPCA 方法时, 按 Tan 等人在 Aw-SpPCA 一文中建议的最佳参数^[11] 进行实验. 即 AR 数据集选取 6×6 大小, Yale 数据集选取 5×10 大小.

对于本文提出的 SpCCA 方法, CCA 中的第一组特征 X 使用将原图像子模式化后的子图像拉伸成的向量; 第二组特征 Y 为对原样本使用 PCA 进行特征提取所得的低维特征. 在提取 X 和 Y 时, 我们面临着如何选取合适的子图像块大小及如何选取 PCA 所提取的低维特征维数的问题, 其中前者是子模式方法都会遇到的, 后者是本方法所特有的, 我们可以使用交叉验证法选择参数, 但这样做将消耗大量时间, 且所得的参数并不一定具有推广性.

以下我们分别设计一组实验来考察两组参数对分类性能的影响, 并得出应如何选取这两组参数的一些参考.

图 4~8 中实验结果以分类正确率表示, 其中纵坐标为正确率, 横坐标为所用方法降至的维数 (实验计算了所有可能的维数), 图中曲线上标明的数值表

示该方法在该点上取得最大值. 图 8 各方法的最大值在前 25 维即达到, 且 25 维以后的正确率曲线趋于平稳, 为了更清晰地展示方法间的区别, 只取了前 25 维作图.

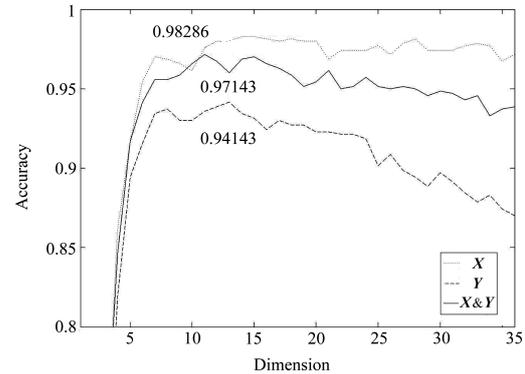


图 4 SpCCA 方法使用不同特征组合在 AR77 数据组上的正确率比较

Fig. 4 Accuracies of SpCCA using different features on AR77 database

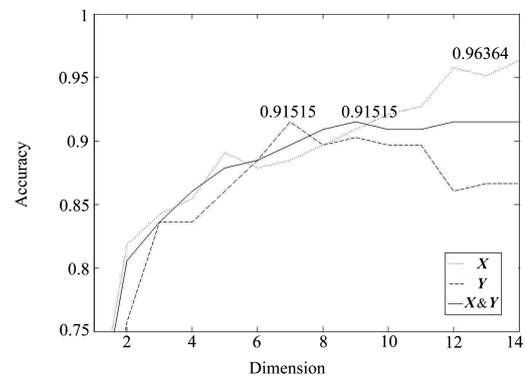


图 5 SpCCA 方法使用不同特征组合在 Yale 数据集上的正确率比较

Fig. 5 Accuracies of SpCCA using different features on Yale database

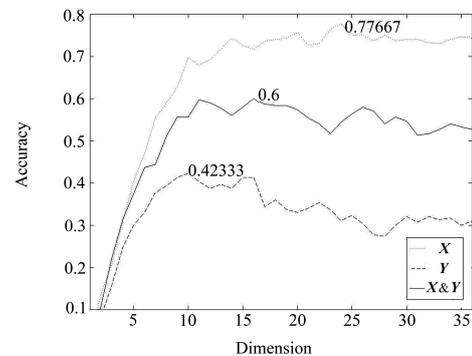


图 6 SpCCA 方法使用不同特征组合在 AR73SungS2 数据组上的正确率比较

Fig. 6 Accuracies of SpCCA using different features on AR73SungS2 database

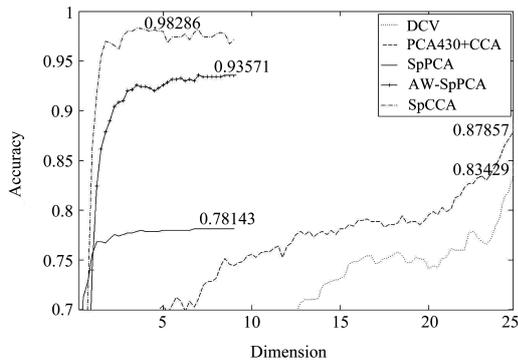


图 7 DCV、PCA+CCA、SpPCA、Aw-SpPCA、SpCCA 在 AR77 数据组上的正确率比较

Fig. 7 Accuracies of DCV, PCA+CCA, SpPCA, Aw-SpPCA and SpCCA on AR77 database

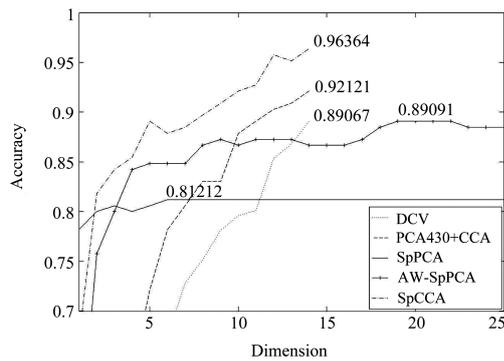


图 8 DCV、PCA+CCA、SpPCA、Aw-SpPCA、SpCCA 在 Yale 数据集上的正确率比较

Fig. 8 Accuracies of DCV, PCA+CCA, SpPCA, Aw-SpPCA and SpCCA on Yale database

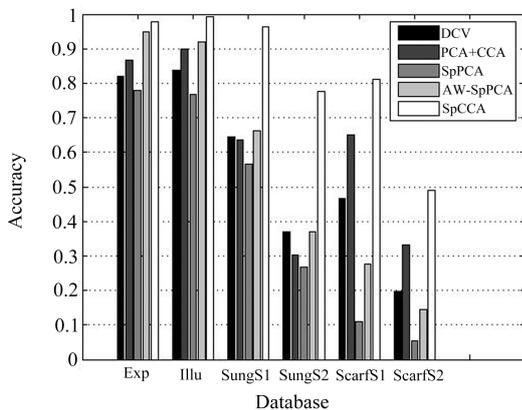


图 9 DCV、PCA+CCA、SpPCA、Aw-SpPCA、SpCCA 在 AR 局部变化数据组上的正确率比较

Fig. 9 Accuracies of DCV, PCA+CCA, SpPCA, Aw-SpPCA and SpCCA on images with local variants from AR database database

图 9 比较了 5 种方法在 6 个不同的局部变化数

据组上的性能, 图中柱高表示该方法在各种参数情况下的最高正确率, 其对应的精确数值及实验参数见表 2 (见下页).

表 3~8 (见第 27 和 28 页) 中第 1 行的“SpCCA to”表示 SpCCA 方法最终降至的维数, 在 AR 上每间隔 4 维取样一次, 在 Yale 上每间隔 2 维取样一次.

2.3 实验结果与分析

以下实验分三部分进行, 第一部分为参数选择, 第二部分为各种方法比较, 这两部分实验使用第一种图像划分方法, 即无重叠划分方式; 第三部分实验使用第二种图像划分方法, 即重叠划分方式.

第一部分实验用于考察两组参数对分类性能的影响. 首先, 为了使 CCA 的两组特征矢量 \mathbf{X} 、 \mathbf{Y} 构成的总体协方差矩阵非奇异, 应满足式 (1) 和式 (2). 在这个范围之内, 设计两组实验, 观察 \mathbf{X} 、 \mathbf{Y} 的维数对识别率的影响.

实验 1. 使用直觉上较好的分块方式: 分块大小中等、且接近方形, 在 AR77、AR73 SungS2 以及 Yale 上实验. AR 数据集的两组数据使用 6×6 大小的子块, 变动 PCA 降至的维数从 5~695, 每 30 维取样一次, 结果发现在维数为 5、35 和 695 时, 正确率较低, 而在 65~665 时均变化不大, 实验结果详见表 3 和表 4, 表中第 2 行为 SpCCA 方法降至第 1 行的维数时, \mathbf{Y} 取 PCA 降至的维数从 65~665, 每 30 维取样一次所得 21 个结果的均值, 第 3 行为这 21 个结果的均方差, 均方差的数值都小于 26%, 这说明了 \mathbf{Y} 取 PCA 降至的维数从 65~665 时, 正确率变化不大. Yale 数据集使用 5×5 大小的子块, 变动 PCA 降至的维数从 5~140, 每 15 维取样一次, 结果发现在维数为 5 时, 正确率较低, 而从 20~140 时均变化不大, 实验结果详见表 5, 同样可得当 \mathbf{Y} 取 PCA 在 20~140 维之间变动时, 正确率变化也不大.

可见, 第二组特征 \mathbf{Y} 所选取的 PCA 特征维数具有很强的鲁棒性, 在中间的很大范围内, 任意选取 PCA 降至的维数, 最终的分类结果变化幅度都很小. 去除最低的 10% 的维数和最高的 10% 的维数, 运用该方法时, 可以在中间 80% 的维数中任选一 PCA 特征维数作为实验参数, 以下实验中在 AR 数据集上我们选取 PCA 至 455 维, 在 Yale 数据集上选取 PCA 至 80 维.

实验 2. 在由实验 1 选取 \mathbf{Y} 的维数后, 改变 \mathbf{X} 的大小, 尝试所有能整除原图像大小、且满足式 (1) 的划分. 在 AR77 和 Yale 数据集上实验, 结果见表 9 和表 10 (见第 28 页), 表中第 1 列为子块行数, 第 2 列为子块列数, 第 3 列为子块大小, 第 4 列为在 \mathbf{X}

表 2 图 9 对应的数据

Table 2 Data for Fig. 9

	DCV		PCA + CCA		SpPCA		Aw-SpPCA		SpCCA	
	识别率	方法	识别率	方法	识别率	方法	识别率	方法	识别率	方法
	(%)	参数	(%)	参数	(%)	参数	(%)	参数	(%)	参数
AR73Exp	82.00	99	86.67	640; 99	78.00	11	95.00	28	97.67	455; 15
AR73Illu	83.67	99	90.00	690; 99	76.67	21	92.00	22	99.33	455; 14
AR73SungS1	64.33	99	63.67	680; 96	5.667	10	66.33	21	96.33	455; 15
AR73SungS2	37.00	98	30.33	580; 99	2.667	10	37.00	21	77.67	455; 24
AR73ScarfS1	46.67	99	65.00	410; 99	11.00	23	27.67	27	81.00	455; 31
AR73ScarfS2	19.67	99	33.33	320; 97	5.33	14	14.33	20	49.00	455; 36

表 3 SpCCA 识别率 (%)— AR77 数据组上变化的 PCA 参数

Table 3 Accuracies (%) of SpCCA — on AR77 and changing PCA parameter

SpCCA to	4	8	12	16	20	24	28	32	36
Avg (65~665)	84.10	95.96	97.12	97.50	97.47	97.37	97.52	97.31	97.14
Std (65~665)	1.66	0.61	0.65	0.59	0.41	0.41	0.23	0.43	0
Chosen (455)	86.14	96.86	98.00	98.14	98.00	97.43	98.14	97.71	97.14

表 4 SpCCA 识别率 (%)— AR73SungS2 数据组上变化的 PCA 参数

Table 4 Accuracies (%) of SpCCA — on AR73SungS2 and changing PCA parameter

SpCCA to	4	8	12	16	20	24	28	32	36
Avg (65~665)	30.54	58.97	68.17	71.98	74.00	74.10	74.33	74.08	74.33
Std (65~665)	2.30	2.47	2.38	2.57	2.19	2.07	1.84	1.16	0
Chosen (455)	30.67	59.00	69.33	71.67	75.67	77.67	75.00	73.33	74.33

表 5 SpCCA 识别率 (%)—Yale 数据组上变化的 PCA 参数

Table 5 Accuracies (%) of SpCCA — on Yale and changing PCA parameter

SpCCA to	2	4	6	8	10	12	14
Avg (20~140)	77.04	85.32	88.96	90.64	93.27	94.55	95.15
Std (20~140)	7.50	2.12	1.04	1.46	1.37	0.74	1.09
Chosen (80)	81.82	85.46	87.88	89.70	92.12	95.76	96.36

表 6 重叠 SpCCA 识别率 (%)— AR77

Table 6 Accuracies (%) of overlapped SpCCA — on AR77 database

SpCCA to 重叠参数	4	8	12	16	20	24	28	32	36
00	86.14	96.86	98.00	98.14	98.00	97.43	98.14	97.71	97.14
23	93.86	98.14	99.00	98.71	98.86	98.71	98.43	98.14	98.14
33	94.71	98.29	99.29	99.00	99.14	99.14	98.57	98.29	98.29
44	95.29	98.71	99.14	99.14	99.14	99.14	99.00	98.57	98.57

表 7 重叠 SpCCA 识别率 (%)— AR73SungS2

Table 7 Accuracies (%) of overlapped SpCCA — on AR73SungS2 database

SpCCA to 重叠参数	4	8	12	16	20	24	28	32	36
00	30.67	59.00	69.33	71.67	75.67	77.67	75.00	73.33	74.33
23	44.67	72.00	79.00	79.67	79.00	79.33	80.33	81.67	79.00
33	48.00	74.00	77.33	79.00	80.67	83.00	82.67	81.00	80.33
44	48.67	74.67	82.00	84.00	84.33	84.00	83.33	83.00	81.67

表 8 重叠 SpCCA 识别率 (%)— Yale

Table 8 Accuracies (%) of overlapped SpCCA — on Yale database

SpCCA to 重叠参数	2	4	6	8	10	12	14
00	81.82	85.46	87.88	89.70	92.12	95.76	96.36
33	78.79	86.67	90.30	92.12	95.15	96.97	96.36

表 9 SpCCA 变化的分块方式参数 — AR77

Table 9 Changing the dividing parameter of SpCCA — on AR77 database

Row	Col	Subsize	Accuracy>97%	All	Rate
6	4	24	17	24	0.71
6	6	36	24	36	0.67
3	8	24	16	24	0.67
2	12	24	15	24	0.63
6	2	12	7	12	0.58

表 10 SpCCA 变化的分块方式参数 — Yale

Table 10 Changing the dividing parameter of SpCCA — on Yale database

Row	Col	Subsize	Accuracy>95%	All	Rate
5	5	25	3	14	0.21
10	2	20	3	14	0.21
5	2	10	2	10	0.20
10	1	10	2	10	0.20
2	10	20	2	14	0.14

选取该子块, SpCCA 降至不同维数时, 识别率大于某值的结果个数, 第 5 列为该分块方式最多可降至的维数, 第 6 列等于第 4 列除以第 5 列, 第 6 列的数值越大, 说明该分块方式中取得较好正确率的机会越高, 同时该分块方式更具有稳定性与较高识别率。

对 AR77 数据, 分块大小可以从 1~528, 表 9 中列出按第 6 列排前 5 位的分块方式, 其块大小为 12~36; 对 Yale 数据, 分块大小为 1~125, 表 10 中列出排前 5 位的分块方式, 其块大小为 10~25。这

与第 1.1 节中分块不能过大或过小的观点相吻合。实验中 AR 图像大小为 $66 \times 48 = 3168$, 最好的 3 组结果大小为 24 (6×4 与 3×8 两种情况) 和 36, 大约为原图像的 $1/100$; Yale 图像大小为 $50 \times 50 = 2500$, 最好的 2 组结果大小为 25 和 20, 也大约为原图像的 $1/100$ 。可见子块大小在原图像大小的 $1/100$ 附近时, 可以取得较好效果。

分块的形状对识别影响的规律在表中难以总结获得, 但我们注意到按照原图像行数的 $1/10$ 和列数的 $1/10$ 划分的子块在识别率上都有好的表现, 如 AR77 中的 6×4 和 6×6 分别排在第 1、2 两位, Yale 中的 5×5 排在第 1 位。按行数的 $1/10$ 和列数的 $1/10$ 划分也正好满足子块大小大约为原图像的 $1/100$ 。综合上述两点, 在选取子块划分方式时, 可以选择按行数的 $1/10$ 和列数的 $1/10$ 的方式进行划分。以下实验中 AR 数据集上我们选取 6×6 分块方式, Yale 数据集上选取 5×5 分块方式。

实验 3. 在确定了基本的实验参数后, 我们改变所选取的特征, 分别使用第一组特征 (局部特征)、第二组特征 (全局特征) 以及共同使用两组特征。实验结果如图 4~6 所示。在 AR77、Yale 以及 AR73SungS2 三个数据集上, 结果都一致显示单独使用 X 特征 (即局部特征) 的正确率曲线最高, 单独使用 Y 特征 (即整体特征) 的正确率曲线最低, 而同时使用 X 与 Y 特征时, 正确率曲线在两者之间, 这与第 1.3 节中的推测是一致的。在图 6 中, 单独使用局部特征与单独使用全体特征的最高识别率相差了 35%, 共同使用两组特征的识别率基本是在分别使用两者之间, 这正是因为整体特征缺乏对局部遮挡的鲁棒性造成的。虽然提取后的 Y 特征融合了部分局部信息, 但它仍是以整体特征为主体, 因而对

AR73SungS2 数据组中的墨镜遮挡不鲁棒, 从而导致了其较低的识别率. \mathbf{X} 与 \mathbf{Y} 的组合特征虽然包含有局部特征, 但也因为加入了过量的全局特征而使其效果下降, 由于 \mathbf{X} 与 \mathbf{Y} 特征是同等混合的, 所以可以看到其曲线也正好在 \mathbf{X} 与 \mathbf{Y} 中间. 由此可见 \mathbf{Y} 特征在本方法的表示中对识别是有害的, 因此在以下的实验中我们只使用 \mathbf{X} 特征 (局部特征).

在第二部分实验中, 我们横向比较了五种不同的方法: 基于整体的 PCA + CCA 和 DCV、基于联合方式的局部方法 SpPCA、基于投票方法的局部方法 Aw-SpPCA 以及本文提出的 SpCCA 在 AR 与 Yale 两个数据集上的表现.

实验 4. 在 AR77 与 Yale 上进行. 结果如图 7~8 所示, 图中纵坐标为识别正确率, 横坐标为所降至的维数. 从图中可见, 融合了整体与局部信息、并使用投票子模式方法降低局部变化对全局影响的 SpCCA 在两个数据集上都取得了比其他四个方法高得多的识别率. 在 AR 数据集上 SpCCA 的最高正确率为 98.286%, 比其次位的 Aw-SpPCA 提高了 4.7%, 在 Yale 数据集上 SpCCA 的最高正确率为 96.364%, 比其次位的 PCA + CCA 提高了 4.2%, 且在目标维数不很低 (图 7 中 ≥ 4 , 图 8 中 ≥ 2) 的情况下, SpCCA 在两个数据集上的正确率曲线都在其他四种方法之上.

为了进一步考察 SpCCA 方法在各种局部变化上的鲁棒性, 我们在 AR 数据集上设计了第二组实验 — 实验 5.

实验 5. 分别在 AR73Exp, AR73Illu, AR73-SungS1, AR73SungS2, AR73ScarfS1 和 AR73-ScarfS2 上进行. 该实验只取正确率最高的结果做柱状图. 图 9 中的结果显示 SpCCA 在 AR 数据集上对表情、光照、墨镜、围巾等局部变化的效果都优于其他四种对比方法. 在光照变化实验的 300 张图像中, SpCCA 仅分错 2 张; 在墨镜、围巾遮挡的实验中, SpCCA 的最高正确率比其余方法一致地提高了 30%~50%. 可见 SpCCA 对各种局部遮挡的识别鲁棒性比其余四种方法都有很大的提高.

在表 2 中, 行代表数据分组, 列代表方法. DCV 参数为方法降至的维数; PCA + CCA 参数中, 前者为 PCA 降至的维数, 后者为 CCA 降至的维数; SpPCA 与 Aw-SpPCA 的参数为每个子块用 PCA 降至的维数; SpCCA 的参数中, 前者为 CCA 中 \mathbf{Y} 使用的 PCA 降至的维数, 后者为整体方法将每个子块降至的维数.

在第三部分实验中, 我们尝试了改变分块方式, 将原来不重叠的平均分块变为重叠的平均分块. 在 AR77, AR73SunglaS2 以及 Yale 上进行实验.

重叠方式见第 1.1 节图 2 所示, 重叠实验结果

见表 6~8. 表中重叠参数的第 1 位和第 2 位分别表示水平重叠与垂直重叠的像素数. 00 代表不重叠, 数字越大代表重叠越多.

在表 6~8 中, 正确率都随着重叠数的增加而上升. 当重叠参数为 44 — 即重叠 9 次时, AR77 的最大正确率比不重叠时增大了约 1%, 达到 99.14%; AR73SungS2 上升了 6.66%; Yale 也有少量上升. 重叠数高时, 结果将更快地趋于稳定. 在 AR77 上, 重叠参数为 44、SpCCA 降至 8 维时, 结果即达到 98.71%, 已趋于稳定, 而不重叠时则需要到 12 维左右才趋于稳定; 在 AR73SungS2 上重叠参数为 44 时, 12 维即稳定, 不重叠时则需要到 20 维才稳定; Yale 上稳定维数也有所降低. 可见分块的重叠对识别率与算法稳定性都有所改进.

当然这种方式的改进需要付出时间代价, 以 AR77 为例, 重叠参数分别取 00、23、33 和 44 时, 在 Matlab 中平均运算时间比约为 1:2.08:3.33:5.56. 在实际应用时, 可以根据需要调整重叠参数, 以平衡识别率与运算时间.

3 总结及后续工作

本文基于 CCA 与子模式方法提出了 SpCCA, 并与 DCV、PCA + CCA、SpPCA、Aw-SpPCA 在人脸识别的效果上进行了比较. 实验证明, SpCCA 利用 CCA 融合整体特征与局部特征, 同时继承了 PCA 方法对全局信息的描述能力与子模式方法注重局部信息、对局部变化具有鲁棒性的优点, 解决了 CCA 在人脸识别中存在的小样本问题, 在光照、表情、遮挡等局部变化的人脸数据库上表现出较好的识别能力. 在实验中使用的两个人脸数据集上超过了其他四种对比方法.

本文运用 CCA 融合整体与局部特征, 以改善所提取的特征的性能. 文中使用的局部信息为对原图像直接划分后所得的子图像, 全局信息为 PCA 提取出的特征. 事实上这两组特征可以根据需要替换为任何满足维数条件 (1) 和 (2) 的特征. 寻找更好的局部与全局特征以改善本算法的分类性能, 将现在融合全局与局部 2 个层次的信息改进为融合多个层次的信息以及将本算法推广到分类以外的回归、重建等领域是我们今后准备研究的三个方向.

References

- Jolliffe I T. *Principal Component Analysis (Second Edition)*. Berlin: Springer, 2002
- Belhumeur P N, Hespanha J P, Kriegman D J. Eigenfaces vs. Fisher faces: recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, **19**(7): 711–720
- Hotelling H. Relations between two sets of variates. *Biometrika*, 1936, **28**(3): 321–377

- 4 Sun Q S, Zeng S G, Liu Y, Wang P A, Xia D S. A new method of feature fusion and its application in image recognition. *Pattern Recognition*, 2005, **38**(12): 2437–2448
- 5 Sun Quan-Sen, Zeng Sheng-Gen, Wang Ping-An, Xia De-Shen. The theory of canonical correlation analysis and its application to feature fusion. *Chinese Journal of Computers*, 2005, **28**(9): 1524–1533
(孙权森, 曾生根, 王平安, 夏德深. 典型相关分析的理论及其在特征融合中的应用. *计算机学报*, 2005, **28**(9): 1524–1533)
- 6 Sun Q S, Zeng S G, Wang P A, Xia D S. Feature fusion method based on canonical correlation analysis and handwritten character recognition. In: *Proceedings of the 8th International Conference on Control, Automation, Robotics and Vision*. Kunming, China: IEEE, 2004. 1547–1552
- 7 Yang Jian, Yang Jing-Yu, Ye Hui. Theory of Fisher linear discriminant analysis and its application. *Acta Automatica Sinica*, 2003, **29**(4): 481–493
(杨健, 杨静宇, 叶晖. Fisher 线性判别分析的理论研究及其在应用. *自动化学报*, 2003, **29**(4): 481–493)
- 8 Cevikalp H, Wilke M. Face recognition by using discriminative common vectors. In: *Proceedings of the 17th International Conference on Pattern Recognition*. 2004. 326–329
- 9 Liu Jun, Chen S C. Discriminant common vectors versus neighbourhood components analysis and Laplacian faces: a comparative study in small sample size problem. *Image and Vision Computing*, 2006, **24**(3): 249–262
- 10 Chen S C, Zhu Y L. Subpattern-based principal component analysis. *Pattern Recognition*, 2004, **37**(1): 1081–1083
- 11 Tan K R, Chen S C. Adaptively weighted sub-pattern PCA for face recognition. *Neurocomputing*, 2005, **64**: 505–511
- 12 Belhumeur P N, Kriegman D J. The Yale face database [Online], available: <http://giskard.eng.yale.edu/yalefaces/yalefaces.html>, 1997
- 13 Johansson B. On Classification: Simultaneously Reducing Dimensionality and Finding Automatic Representation Using Canonical Correlation. Technical Report LiTH-ISY-R-2375, Öping University, Sweden, 2001
- 14 Feng G C, Yuen P C, Dai D Q. Human face recognition using PCA on wavelet subband. *Journal of Electronic Imaging*, 2000, **9**(2): 226–233
- 15 Loizou G, Maybank S J. The nearest neighbor and the Bayes error rates. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1987, **9**(2): 254–262
- 16 Martinez A M, Benavente R. The AR Face Database. CVC Technical Report # 24, Purdue University, 1998



洪泉 南京航空航天大学硕士研究生。主要研究方向为模式识别。
E-mail: nausicaaathene@yahoo.com.cn
(HONG Quan Master student at Nanjing University of Aeronautics and Astronautics. His research interest covers pattern recognition.)



陈松灿 南京航空航天大学教授。主要研究方向为模式识别、机器学习与神经计算。本文通信作者。

E-mail: s.chen@nuaa.edu.cn
(CHEN Song-Can Professor at Nanjing University of Aeronautics and Astronautics. His research interest covers pattern recognition, machine learning, and neural computing. Corresponding author of this paper.)



倪雪蕾 南京航空航天大学硕士研究生。主要研究方向为模式识别。

E-mail: dodosweets@hotmail.com
(NI Xue-Lei Master student at Nanjing University of Aeronautics and Astronautics. Her research interest covers pattern recognition.)