

基于PCA及ICA的双空间特征提取算法

王卫东^{1,2)} 韩斌¹⁾ 杨静宇²⁾

¹⁾(江苏科技大学电子信息学院计算机系,镇江 212003) ²⁾(南京理工大学计算机系,南京 210094)

摘要 任何一种单子空间特征提取算法都不能在任何情况下优于其他子空间算法,但是采用双子空间却可以克服单子空间的局限性。为了提高分类结果的正确率,提出了一种基于PCA及ICA的双空间特征提取算法,该算法采用ICA作为PCA的补空间进行特征提取,其目的是将在PCA子空间中难以识别的样本,再次投影到ICA子空间中进行识别。该算法可分为以下两个步骤:首先进行预分类,即在一个子空间内同时使用两种分类器对测试样本进行分类,若某个测试样本被两种分类器划分到不同的类,则将该测试样本加入到新测试样本集中;然后将新测试样本集中的测试样本再次投影到另一个子空间中进行分类识别;最后,将识别结果与预分类结果一起进行正确率测试。在ORL及FERET人脸库上的实验结果表明,该算法的模式识别率明显优于传统的特征提取算法。

关键词 双空间算法 主成分分析 独立成分分析 特征提取 人脸识别

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2008)11-2163-07

Dual-space Feature Extraction Algorithm Based on PCA and ICA

WANG Wei-dong^{1,2)}, HAN Bin¹⁾, YANG Jing-yu²⁾

¹⁾(Department of Compute, School of Electronic and Information Engineering, Jiangsu University of Science and Technology, Zhenjiang 212003)

²⁾(Department of Computer Science, Nanjing University of Science & Technology, Nanjing 210094)

Abstract No single subspace feature extraction algorithm outperforms others under all circumstances, but applying dual-space feature extraction algorithm can overcome the limits of single subspace. To increase the recognition rate of classified results, a new dual-space feature extraction algorithm is put forward based on PCA (principal component analysis) and ICA (independent component analysis). The algorithm uses ICA as PCA's complementary space to realize feature extraction. The aim of the algorithm is to re-project the samples into ICA subspace to classify, which are difficult to be classified in PCA subspace. The proposed dual-space extraction algorithm includes two steps. Step 1 is called pre-classify, which uses two classifiers in a single subspace to classify the testing samples. If a testing sample is classified into different classes by two classifiers, it would be added into the new testing samples set. In step 2, the algorithm projects the samples of the new testing samples set into another subspace and classifies them. Then, the recognition results of two subspaces are tested together. The experimental results in ORL and FERET database prove the dual-space feature extraction algorithm outperforms the traditional feature extraction algorithm in recognition rate.

Keywords dual-space algorithm, principal component analysis, independent component analysis, feature extraction, face recognition

基金项目:国家自然科学基金项目(60472060)

收稿日期:2007-02-12;改回日期:2007-07-13

第一作者简介:王卫东(1968~)男。2007年获南京理工大学博士学位,现为江苏科技大学讲师。主要研究方向为模式识别及数据融合等。E-mail: wang_wdong@yahoo.com.cn

1 引言

目前在单特征子空间中还没有一种特征提取或分类器算法可以在任何情况下均优于其他算法,而双空间^[1]和多空间^[2-4]算法则希望通过双特征子空间或多特征子空间中的模式特征进行融合来克服单特征子空间的限制,并实现高于单特征子空间方法的模式识别率。其中,Wang 等人提出的双空间线性鉴别分析方法^[1],是利用类内协方差矩阵 S_w 的主子空间和零空间来分别生成投影矩阵,当模式被投影到两个特征子空间后,则可将得到的特征向量融合在一起进行分类识别,其已取得了较好的识别结果。Kam Ho 提出了随机子空间法^[2],该方法从原高维模式特征空间出发,首先生成一系列低维随机特征子空间,然后在随机特征子空间中对模式进行分类识别,最后将识别结果进行融合后输出。

传统的双、多空间算法的共同特点是将不同特征子空间的特征向量融合在一起用来提高特征向量的分类能力。但是,虽然两个特征向量在各自的子空间中具有很好的分类能力,当将它们结合起来看作一个特征向量时,则由于相关性较强,可能得不到什么信息,因此,在双空间中采用特征融合方法,对于某些情况,可能不但增加了复杂性,而且没有收获。事实上,在一个特征子空间中,某些模式可能是易于识别的,而有些则是难于识别的。在将模式投影到另一个特征子空间后,原来难于识别的模式可能变成易于识别的,而原来易于识别的模式却可能会变为难于识别的。因此,如果可以在一个特征子空间中分离出哪些模式是易于识别的,哪些模式是难于识别的,那么就可以将难于识别的模式再投影到另一个特征子空间中进行识别。若两个特征子空间具有一定的互补性,则在后一个子空间中就可能对这些模式做出正确的分类。以上就是本文双空间特征提取算法的基本思想。

本文算法的关键是在一个特征子空间中如何将模式分为易于识别的和难于识别的两部分。本文采用预分类方法实现上述功能。本文算法的另一个难点在于:两个特征子空间应具有一定的互补性,即强调两个特征子空间的差异性。因此,双空间的选取要综合考虑模式特征的分类能力及互补性。本文采用主成分分析 (PCA)^[5,6] 及独立成分分析

(ICA)^[7-10] 组成双空间。PCA 是在最小协方差意义下给出的模式样本的最优表示,由于 PCA 只考虑了二阶统计信息,而没有利用图像的高阶统计信息,因此,PCA 是基于信号二阶统计特性的分析方法,其作用是去除图像各分量之间的相关性。ICA 是基于信号高阶统计特性的分析方法。ICA 为非高斯数据找到了一种线性变换,它可使成分与成分之间是统计独立的或者是尽可能独立的,而基于 ICA 的特征提取方法,则不仅可使被分析信号各成分之间的统计依赖性达到最小,而且突出了源信号的本质结构,因此,由 PCA 和 ICA 所生成的特征子空间应具有较好的互补性,非常适于本文的双空间特征提取算法。

2 独立成分分析

2.1 ICA 的定义

ICA 起源于盲源信号分离 (blind source separation, BSS), BSS 是研究根据给定的混合信号 \mathbf{x} 重构出源信号 \mathbf{s} 。ICA 的目标是将观察到的数据通过某种线性分解,使其分解成统计独立的成分。假设输入的随机数据向量 \mathbf{x} 确实是通过统计独立的线性组合来合成的,并且从严格意义上讲,成分是固定的,即

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s} \quad (1)$$

式中, $\mathbf{s} = [s_1, s_2, \dots, s_m]^T$ 是 m 维零均值的源信号向量,其分量是相互独立的。 $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ 是 n 维观测信号向量。 \mathbf{A} 是 $n \times m$ 大小的混合矩阵。式(1)表示被观察到的数据是如何由独立成分混合而产生的。独立成分是隐藏的变量,其意味着它不能被直接观察到,而且混合矩阵也被假设为未知的,所有能观察到的仅仅只是随机向量 \mathbf{x} 。

ICA 的任务是:给定一个输入样本 \mathbf{x} , 通过确定一个可逆矩阵 \mathbf{W} , 使得变换后的向量为 \mathbf{y} , 即

$$\mathbf{y} = \mathbf{W} \cdot \mathbf{x} \quad (2)$$

式中, $y_i (i = 1, 2, \dots, m)$ 是源信号 \mathbf{s} 的估计值。

2.2 ICA 的基本算法

假设所有独立成分都有相同的分布,且 $m = n$, 这样就可以认为 \mathbf{W}^{-1} 是 \mathbf{A} 的估计,在理想情况下, $\mathbf{W} = \mathbf{A}^{-1}$ 。由式(2)可知,为了估计其中的一个独立成分 y_i , 可考虑 $y_i = \mathbf{w}_i^T \mathbf{x}$ 的线性组合,这里 \mathbf{w} 是一个待定的向量,如果 \mathbf{w}_i^T 是矩阵 \mathbf{W} (\mathbf{A} 的逆)的一个行向量,则这个线性组合实际上将等于一个独立成分。

但是并不能确切地确定 w , 因为并不知道矩阵 A , 但是可以找到一个很接近的估计。若将变量进行如下变换, 即定义 $z = A^T w$, 则有

$$y = w^T x = w^T A s = z^T s \quad (3)$$

式中, y 是 s 的一个线性组合, 其权重由 z 给出。如果把 w 看作是最大化非高斯 $w^T x$ 的一个向量, 且该向量对应于 z , 则有 $w^T x = z^T s$ 等于其中的一个独立成分。而最大化 $w^T x$ 的非高斯性, 即可得到一个独立成分。当前 ICA 的估计模型主要包括非高斯的极大化、互信息的最小化、最大似然函数估计 (ML), 其中非高斯极大化包括 Kurtosis 系数、负熵及负熵的近似。

2.3 FastICA 算法

通常对 ICA 方法的求解, 可以按照以下几个步骤进行: 首先是数据 (混合信号) 的预处理, 包括中心化和白化; 然后通过选择和定义非高斯性的度量来建立目标函数, 该函数取极值时, 其估计出的独立成分间的非高斯性最大, 该函数代表了一种分离准则, 根据不同的分离准则将可推导出不同的算法; 最后, 用某种最优化方法来求最大 (小) 化目标函数, 即可推导出一种学习算法。

FastICA 是一种快速 ICA 算法^[10], 它对任何类型的数据都适用, 同时它的存在使运用 ICA 来分析高维数据成为可能。该算法通过系统学习, 可找到一个方向, 即单位向量 w , 使其投影 $w^T x$ 具有最大的非高斯性。FastICA 是采用以下公式行非高斯性度量

$$N(y) \approx \sum_{i=1}^k k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2 \quad (4)$$

其中, k_i 为一正的常量, v 为零均值的单位方差的高斯变量。函数 G_i 为非二次函数。该算法是基于定点递推算法寻找 $w^T x$ 的非高斯性最大值, 且每次只从观测信号中分离出一个独立分量。

3 基于 PCA 及 ICA 的双空间算法

3.1 算法思想

图 1 是本文算法的原理示意图。

本文双空间特征提取算法的关键是要将测试样本分为以下两部分: 一部分是在某个子空间中容易识别的; 另一部分则是在该子空间中不易识别的。图 1 中的三角形及矩形分别表示两类测试样本, 图 1(a) 表示如果将测试样本向 X 方向投影, 则当测试样本处于两条黑线之外时, 其被错分的概率很小;

而对于处在两条黑线之内的测试样本, 则由于两类样本的投影相互重叠, 故在该子空间中, 被错分的应是处于两条黑线之内的测试样本。图 1(b) 表示如果将测试样本向 Y 方向投影, 则当测试样本处于两条黑线之外时, 被错分的概率很小; 而对于处在两条黑线之内的测试样本, 则被错分的概率较大。从图 1(b) 可以看出, 黑色表示的样本是在前一个子空间中可以被正确识别的, 而在后一个子空间中则可能被错分; 深灰色样本是在前一个子空间可能被错分, 而投影到后一个子空间中, 则可以正确分类; 白色样本是在两个子空间中都可能被错分的测试样本。本文的双空间算法就是要在 a 子空间中, 将可能错分的测试样本再投影到 b 子空间中进行分类识别, 这样就有可能对某些在 a 子空间中难以识别的样本, 在 b 子空间中能对其做出正确的分类, 即在图 1(b) 中用深灰色表示的样本。在图 1(b) 中, 由于浅灰色样本在两个子空间中都不会被错分, 因此其差别结果不受本文双空间算法影响。

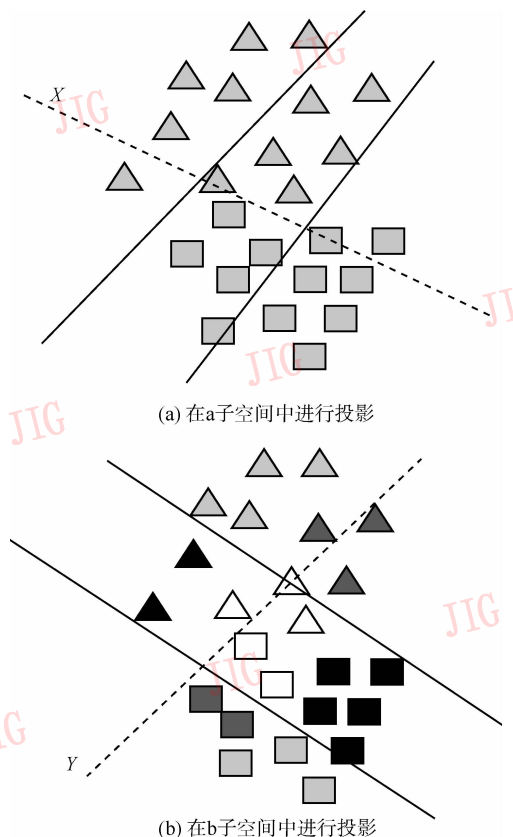


图 1 双空间算法的原理示意图

Fig. 1 Principle figure of dual-space algorithm

为了实现上述双子空间算法, 本文在 a 子空间采用预分类方法, 先将测试样本分成易于识别的和

难于识别的两部分,其具体的方法就是对测试样本同时采用两种不同的分类器进行预分类,并对分类结果进行融合,当两种分类器的分类结果相同时,就认为该分类结果是“可能正确”的,并将该结果作为预分类结果,当两种分类器的分类结果不同时,则认

为该测试样本在 PCA 生成的特征子空间中是难以分类的;然后,将这部分测试样本再投影到由 ICA 生成的特征子空间中,并进行分类识别。图 2 是算法的原理框图。

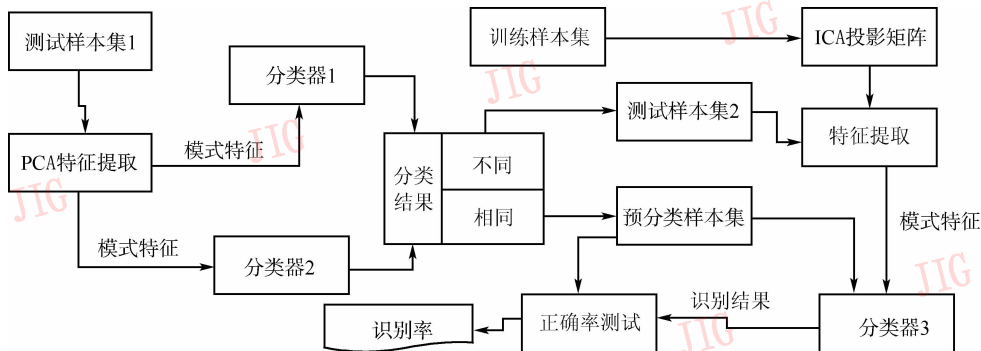


图 2 基于 PCA 及 ICA 双空间算法的算法框图

Fig. 2 Algorithm principle figure of dual-space algorithm based on PCA and ICA

从图 2 中可以看出,双空间算法是采用多分类器组合的方式来实现对测试样本的预分类。经过预分类后,预分类样本集中的测试样本同训练样本一样,也具有了类别标签。预分类可将测试样本集划分为以下两部分:预分类样本集(由预分类结果相同的测试样本组成)和测试样本集 2(由预分类结果不同的测试样本组成)。分类时,先利用训练样本生成 ICA 投影矩阵;然后对测试样本集 2 中的样本进行特征提取,并利用预分类样本集对分类器 3 进行优化;接着对测试样本集 2 进行分类识别,将分类结果与预分类结果一起进行正确率测试;最后以识别率的形式输出。

3.2 算法步骤

设模式类别有 C 个,即 $\omega_1, \omega_2, \dots, \omega_C$,每类有标明类别的训练样本 N_i 个, $i = 1, 2, \dots, C$ 。总的测试样本数为 T 个,则本文算法的算法步骤如下:

(1) 基于 PCA 的模式特征提取 在 PCA 子空间进行特征提取来得到特征向量。

$$\mathbf{X}_p = \{(\mathbf{x}_p)^k \quad k = 1, 2, \dots, T\}$$

其中, \mathbf{X}_p 表示采用 PCA 进行特征提取后的测试样本集,下角 P 表示 PCA 特征子空间。

(2) 预分类 采用两种分类器对模式特征向量进行预分类,即分为以下两类:

$$\mathbf{X}_p^1 = \{(\mathbf{x}_p)_i^k \quad i = 1, 2, \dots, C; k = 1, 2, \dots, T\}$$

$$\mathbf{X}_p^2 = \{(\mathbf{x}_p)_j^k \quad j = 1, 2, \dots, C; k = 1, 2, \dots, T\}$$

其中, $(\mathbf{x}_p)_i^k, (\mathbf{x}_p)_j^k$ 表示将第 k 个未知样本分别判

别为第 i 及第 j 类。

(3) 融合分类结果 对各分类器的分类结果进行融合,将分类结果相同的测试样本组成集合 \mathbf{X}_E (即预分类样本集),下角 E 表示新的训练样本集,而将分类结果不同的测试样本组成集合 \mathbf{X}_D ,其下角 D 代表新的测试样本,对未知样本的分类结果 $(\mathbf{x}_p)_i^k, (\mathbf{x}_p)_j^k$,若 $i = j$,则将 $(\mathbf{x}_p)_i^k$ 加入到 \mathbf{X}_E 中;否则,将 $(\mathbf{x}_p)_i^k$ 加入到 \mathbf{X}_D 中。则

$$\mathbf{X}_E = \{(\mathbf{x}_p)_i^k : (\mathbf{x}_p)_i^k \in \mathbf{X}_p^1, (\mathbf{x}_p)_j^k \in \mathbf{X}_p^2 \text{ 且 } i = j\}$$

$$\mathbf{X}_D = \{(\mathbf{x}_p)_i^k : (\mathbf{x}_p)_i^k \in \mathbf{X}_p^1, (\mathbf{x}_p)_j^k \in \mathbf{X}_p^2 \text{ 且 } i \neq j\}$$

(4) 计算 ICA 投影矩阵 采用 FASTICA 算法,利用训练样本计算 ICA 投影矩阵。

(5) 特征提取 利用 ICA 投影矩阵对测试样本集 \mathbf{X}_D 中的测试样本进行投影,即将在第一个特征子空间中难以识别的测试样本投影到 ICA 特征子空间中。

(6) 采用分类器 3 进行分类 对测试样本集 \mathbf{X}_D 中的测试样本进行分类识别。

(7) 正确率测试 将分类器 3 的分类结果与预分类样本集 \mathbf{X}_E 一起进行正确率测试,并将测试结果以模式识别率的形式输出。

4 实验及分析

4.1 在 ORL 人脸库上的对比实验

ORL 人脸库由 40 人每人 10 幅图像组成,不仅

人的脸部表情和脸部细节有着不同程度的变化;且人脸姿态也有相当程度的变化,深度旋转和平面旋转可达 20°;人脸的尺度也有多达 10% 的变化。原图像为 92 × 112 pixels,需先对训练及测试样本进行两次小波变换,将图像变换为 23 × 28pixels,然后进行特征提取。

实验 1 采用 PCA、Fisherface 及 ICA 进行特征提取的对比实验

实验时,分别取每人的前 4、5、6 幅图像作为训练样本,对应的取每人后 6、5、4 幅作为测试样本,即训练及测试样本集是由不同的人脸图像组成。先采用 PCA、Fisherface 及 ICA 进行特征提取,然后分别采用最小距离、最近邻及正则化判别分析^[11](regularised discriminant analysis, RDA)等分类器进行分类识别。其中 RDA 分类器的参数 λ 、 γ 取为 0.3,实验结果如表 1 所示。

表 1 PCA、Fisherface 及 ICA 的分类精度对比

Tab.1 The results of comparison experiments for PCA、Fisherface and ICA

训练样本数	3 种特征提取方法的分类精度(%)								
	PCA			Fisherface			ICA		
	最小距离分类器	最近邻分类器	RDA 分类器	最小距离分类器	最近邻分类器	RDA 分类器	最小距离分类器	最近邻分类器	RDA 分类器
4	85.00	90.42	90.42	91.25	92.92	90.00	90.83	91.25	84.16
5	89.50	94.50	95.00	93.00	93.50	93.50	89.50	90.00	88.00
6	86.87	91.87	94.30	89.37	93.75	92.50	93.75	93.75	87.50

从表 1 可以看出,当单独使用 PCA 及 ICA 进行特征提取时,其模式识别率并不是很高。尤其是当采用 ICA 进行特征提取,而分类器采用 RDA 分类器时,其识别率甚至低于最小距离分类器,这是由于 ICA 提取的是随机变量的非高斯信息,其从数学的观点来看,ICA 问题对高斯过程来说是病态的,而基于贝叶斯理论的 RDA 分类器,则是在假设各类样本服从高斯分布的基础上设计的,因此采用 ICA 进行特征提取时的识别率较低,而使用 Fisherface 进行特征提取并使用最小距离分类器,其模式识别率高于其他两种特征提取方法。用 PCA 进行特征提取并结合 RDA 分类器进行分类,其所得到的识别率最高。可见不同的特征提取算法与不同分类器相结合,其模式识别率的差异很大。同时没有任何一种单子空间

的特征提取算法可以在任何情况下都优于其他算法。

实验 2 本文算法的分类实验

本文的双空间算法就是为了克服单子空间的限制。实验 2 的实验环境与实验 1 完全相同。由于在用 PCA 生成的单子空间中,使用 RDA 和最近邻分类器的模式识别率都较高,因此,本文算法的预分类采用 PCA 进行特征提取,同时,分别采用 RDA 和最近邻分类器进行预分类。其中 RDA 分类器的参数 λ 、 γ 取为 0.3。而 ICA 作为 PCA 的补空间,用于进行第 2 次特征提取。由表 1 可以看出,由于在 ICA 的特征子空间中,采用最近邻分类器的模式识别率较高,因此,本文算法在 ICA 的特征子空间中使用最近邻分类器,实验结果如表 2 所示。

表 2 基于 PCA 及 ICA 的双空间特征提取方法的分类结果

Tab.2 Feature extraction algorithm of dual-space based on PCA and ICA

训练样本数	预分类结果			双空间分类结果	
	X_D 的样本数	X_E 的样本数	X_E 的错分样本数	错分数	识别率(%)
4	31	209	1	8	96.66
5	15	185	0	7	96.50
6	16	144	1	6	96.25

表 2 中, X_D 的样本数表示的是两种分类器预分

类结果不同的测试样本数,这些测试样本是在 PCA

子空间中难以识别的测试样本。采用这些测试样本组成测试样本集 2。 X_E 的样本数表示两种分类器的预分类结果相同的测试样本数。 X_E 的错分样本数表示两种分类器的分类结果虽然相同,但是被错分的样本数。从实验结果可以看出, X_E 的错分数较少,这说明两种分类器在预分类时,所错分的测试样本大多数都被错分为不同的类。因此,在 PCA 特征子空间中使用的两个分类器具有良好的互补性。虽然使用 ICA 方法进行特征提取时,其模式识别率并不是很高,但是,在本文的双空间算法中,ICA 作为与 PCA 互补的特征子空间,却取得了较高的模式识别率。这是由于利用 ICA 提取的特征向量中含有样本的高阶统计信息,而采用 PCA 方法得到的特征向量仅含有二阶统计信息,因此,在 PCA 特征子空间中不易识别的测试样本,再投影到 ICA 特征子空间中后,则可能就是易于识别的。

实验 3 本文算法与其他双空间算法的对比实验

实验 3 的实验环境与前两个实验完全相同。将文献[1]的双空间算法称为算法 1,同时,采用本文的算法思想,只是将 PCA 的补空间变为 Fisherface,组成 PCA + Fisherface 的双空间算法,在第 2 个子空间中同样使用最近邻分类器进行分类识别。其对比实验结果如表 3 所示。

表 3 与其他双空间特征提取算法的识别率对比

Tab.3 The results of comparison experiments with other dual-space algorithms

训练样本数	各种算法的识别率(%)		
	算法 1	PCA + Fisherface	PCA + ICA
4	94.16	96.25	96.66
5	95.5	96.00	96.50
6	96.25	96.25	96.25

从表 3 中可以看出,采用双空间特征提取算法,其模式识别率都高于表 1 的单空间算法。而采用本文思想的两种双空间算法的模式识别率都高于文献[1]的双空间算法。由于文献[1]算法是将不同特征子空间的特征向量融合在一起,用来提高特征向量的分类能力,但是由于相关性较强,致使某些情况下可能得不到什么信息。

从表 3 中还可以看出,在训练样本数较少,而测试样本数较多时,本文算法的优势更加突出。由于当测试样本较多时,相应地在 PCA 子空间中难以识

别的样本也较多,这时在其补空间进行识别的样本也较多,因此其模式识别率的提升空间就较大。相反,当测试样本较少时,本文算法的优势就较小。当每类只有 1 或 2 个测试样本时,对于多类别的模式识别问题,测试样本的总数仍然较多,这时使用本文的预分类方法同样可以提高模式的识别率,只是提升的空间较小。

对于采用本文思想的两种双空间算法,其模式识别率相差不多,PCA + ICA 算法略优于 PCA + Fisherface 算法。采用 ICA 作为补空间是利用模式的高阶统计信息作为其二阶统计信息的补信息;而采用 Fisherface 作为补空间则是利用模式的最佳鉴别信息作为模式的最优表示的补信息。仅从 ORL 人脸库上还很难看出是 ICA 还是 Fisherface 更适合作为 PCA 的补空间。

4.2 在 FERET 人脸库上的对比实验

FERET 人脸库已经成为测试和评估各种人脸识别算法的标准数据库。本文选取 FERET 数据库的一个子集,其中共有 700 幅图像,包括了 100 人,每人 7 幅图像。本文的图像预处理方法是:首先根据原始图像中人眼睛的位置对图像进行修剪,并将图像的尺寸调整为 80×80 pixels,图像的预处理还进行了直方图均衡化;然后,对所有图像进行两次小波变换,将图像变换为 20×20 pixels。图 3 是该库中某人的 3 幅图像。



图 3 FERET 人脸库中的 3 幅图像

Fig.3 Three images of FERET face database

实验 4 PCA + Fisherface 与 PCA + ICA 的对比实验

在 FERET 人脸库,主要对本文提出的 PCA + ICA 与 PCA + Fisherface 等算法进行对比实验。其中在 PCA 子空间中,同样采用 RDA 和最近邻分类器进行预分类。与 ORL 人脸库的实验不同,实验 4 是在 ICA 子空间中采用最小距离分类器进行分类识别,这样在不同子空间中采用的分类器也各不相同。其他算法同样采用最小距离分类器进行对比实验。实验时,分别取每人的前 3、4 幅图像作为训练

样本,对应的取每人后 4、3 幅图像作为测试样本。其对比实验结果如表 4 所示。

表 4 在 FERET 人脸库上的对比实验

Tab.4 The results of comparison experiments in FERET face database

训练样本数	各种算法的识别率(%)				
	PCA	Fisherface	ICA	PCA + Fisherface	PCA + ICA
3	38.00	56.00	54.50	64.75	64.25
4	49.66	67.66	54.33	74.66	72.33

从表 4 中可以看出,在单子空间中,采用最小距离分类器进行分类识别时,PCA 算法的识别率明显低于 Fisherface 和 ICA 算法,而 Fisherface 算法则明显高于 ICA 算法。采用本文双空间思想组成的 PCA + ICA 算法及 PCA + Fisherface 算法,其模式识别率相差不多,PCA + Fisherface 算法略优于 PCA + ICA 算法。这同 ORL 人脸库上的实验结果非常类似,由此可见,采用本文的双空间思想,利用 ICA 或 Fisherface 作为 PCA 的补空间均可以得到较好的分类结果。本文算法的关键是采用预分类的方法,而且将不同的测试样本分别投影到不同的特征子空间中进行分类识别,就可以克服单特征子空间的局限性。

5 结 论

本文首先讨论了基于双空间的特征提取算法,并采用预分类方法,根据模式特征向量的可分性,将不同的测试样本投影到不同的特征子空间中,这样就避免了将不同的特征向量融合在一起所引起的分类性能下降。从本文双空间算法的实验结果可以看出,采用具有互补性的双空间进行特征提取,并借助于预分类方法就可以得到极高的模式识别率。本文双空间算法的关键是要找到具有互补性的两个特征

子空间。目前,模式的特征提取算法很多,且新算法层出不穷,因此,随着研究工作的进一步深入,很有可能找到更好的双空间组合算法。

参考文献 (References)

- 1 Wang Xiao-gang, Tang Xiao-ou. Dual-space linear discriminant analysis for face recognition [A]. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition [C], Washington, DC, USA, 2004:564 ~ 569.
- 2 Kam Ho T. The random subspace method for constructing decision forests [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, **20**(8):832 ~ 844.
- 3 Fang Yu-chun, Wang Yun-hong, Tan Tie-niu. Personalized feature combination for face recognition [A]. In: Proceedings of the IEEE Region 10 Technical Conference on Computers Communications, Control and Power Engineer (TENCON) [C], Beijing, China, 2002:529 ~ 532.
- 4 Hall D L. Mathematical Techniques in Multisensor Data Fusion [M]. Boston, MA, USA; London, UK: Artech House, 1992.
- 5 Kirby M, Sirovich L. Application of the Karhunen-Loeve procedure for the characterization of human faces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, **12**(1):103 ~ 108.
- 6 Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, **3**(1):72 ~ 86.
- 7 Comon P. Independent component analysis: A new concept [J]. Signal Processing, 1994, **36**(3):287 ~ 314.
- 8 Hyvarinen A. Survey on independent component analysis [J]. Neural Computing Surveys, Lawrence Erlbaum Associates, Inc. 1999, **2**(4):94 ~ 128.
- 9 Li Y, Powers D, Peach J. Comparison of blind source separation algorithms [A]. In: Mastorakis N E, Eds, Advances in Neural Networks and Applications [C], Athens, Greece: World Scientific Engineering Society (WSES) Press, 2001:18 ~ 23.
- 10 Hyvarinen A. Fast and robust fixed-point algorithm for independent component analysis [J]. IEEE Transactions on Neural Networks, 1999, **10**(3):626 ~ 634.
- 11 Friedman J H. Regularized discriminant analysis [J]. Journal of the American Statistical Association, 1989, **84**(405):165 ~ 175.