

# 融合小波变换与 KPCA 的分块人脸特征 抽取与识别算法

谢永华 陈伏兵 张生亮 杨静宇

(南京理工大学计算机科学系, 南京 210094)

**摘要** 鉴于小波多尺度变换对高维图像特征具有良好的压缩和表达能力,提出了一种融合小波变换与 KPCA(核主成分分析)方法的分块人脸特征抽取与识别算法。该算法首先对人脸图像进行分块小波变换,再根据图像块的位置分布选取不同的频率分量;然后对此分量进行 KPCA 特征抽取,并通过对抽取到的特征进行融合来得到最终人脸鉴别特征;最后利用支持向量机分类器进行特征分类与识别。通过对 ORL 和 Yale 标准人脸图像库的实验仿真结果表明,该算法不仅在识别性能和分类速度上明显高于传统的 PCA 方法及融合小波特征的 KPCA 方法,而且对于人脸光照、姿态和表情变化均具有良好的鲁棒性。

**关键词** 小波变换 核主成分分析 分块人脸 特征抽取 支持向量机

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2007)04-0666-07

## Features Extraction and Recognition of Intersected Human Face Based on Wavelet Transform and KPCA

XIE Yong-hua, CHEN Fu-bin, ZHANG Sheng-liang, YANG Jing-yu

(Department of Computer Science, Nanjing University of Science and Technology, Nanjing 210094)

**Abstract** According to powerful compression and expression ability for high-dimensional image of wavelet multi-scale transformation, a feature extraction and recognition technology of intersected human face based on wavelet transform and KPCA(kernel principal component analysis) is proposed in this paper. With this method, the image of human faces are firstly divided into small different pieces which then being transformed with wavelet transformation algorithm. Secondly according to the positions of intersected small images coefficients of different frequency are chosen as extracted wavelet features. Thirdly with KPCA the principal components of these features and then by combining these the ultimate discriminate features are obtained. Finally the features are classified with the classifier of SVM(support vector machine). The experimental results on ORL and Yale face database show that the proposed method is superior to traditional PCA methods and KPCA methods with wavelet transformation, and it is also fairly robust to the variety of different illumination condition, face pose and expression.

**Keywords** wavelet transform, kernel principal component analysis(KPCA), intersected human face, features extraction, support vector machine(SVM)

## 1 引言

人脸自动识别是模式识别与计算机视觉研究领

域的重要研究课题。近年来,人脸识别技术研究非常活跃,其中以 Turk 提出的基于主成分分析(principal component analysis, PCA)的特征脸方法<sup>[1]</sup>和 Belhumeur 提出的基于线性鉴别分析(linear

基金项目:国家自然科学基金项目(60472060,60473039,60503026)

收稿日期:2005-10-11;改回日期:2006-02-16

第一作者简介:谢永华(1976~),男,2002年于南京信息工程大学获得系统分析与集成硕士学位,现为南京理工大学计算机系模式识别与智能系统专业博士研究生。主要研究方向为数字图像处理与模式识别。E-mail:xyh\_76@nuist.edu.cn

discriminant analysis, LDA) 的 Fisher 脸方法<sup>[2]</sup>为代表的子空间法得到了新的发展,并获得了巨大成功。但是无论是 PCA 还是 LDA 方法,它们都只考虑了图像数据中的二阶统计特性,而对多像素之间的依赖性 or 像素的高阶关系并不敏感,但是图像的高阶统计量往往包含了图像边缘或曲线等结构信息的非线性关系,这些关系对图像的识别非常有利。为此, Scholokopf 和 Bandat 通过借鉴 SVM (support vector machine) 的核技巧,将 PCA 方法和 LDA 方法推广到代表非线性领域的高维特征空间,提出了核主成分分析(kernel principal component analysis, KPCA)方法<sup>[3]</sup>以及核 Fisher 鉴别分析(kernel fisher discriminant analysis, KFDA)方法<sup>[4]</sup>。Moghaddam 又对几种子空间的性能进行了比较,证明了核方法能够有效地抽取高维特征空间的非线性鉴别特征,因此比线性子空间法具有更好的特征抽取能力<sup>[5]</sup>。

现有基于 KPCA 特征抽取方法的关键步骤是构造满足 Mercer 条件的核矩阵  $K = (K_{i,j})$ , 其中  $K_{i,j} = K(X_i, X_j)$ ,  $X_i, X_j \in \mathbf{R}^n$ ,  $i, j = 1, \dots, N$ ,  $X$  是原始输入空间中的训练样本,  $N$  是所有训练样本的总数,其构造核矩阵  $K$  所需的时间复杂度为  $O(Nn^2)$ , 这部分时间占整个算法运行时间的 70% 左右。由于人脸图像的识别通常是小样本,甚至是单样本,但是人脸图像向量维数却普遍高达上万维,即  $N \ll n$ , 因而在构造  $K$  之前,若降低训练样本的维数  $n$ , 就会极大地降低整个算法的时间复杂度,从而可提高人脸特征抽取和分类识别的效率。

近年来小波变换以其良好的时频局部化能力,在数字图像处理领域得到了广泛应用。高西奇等提出了基于小波变换的主元分析人脸图像识别算法<sup>[6]</sup>,该算法只对一阶小波变换的低频分量进行 PCA 分析,因而数据量就减少到了原来的四分之一。谢永华等人指出,由于小波变换的高频分量对应于人脸的边缘和轮廓,是人脸最具识别效率的特征之一<sup>[7]</sup>,因此完全舍弃高频分量会降低分类识别的效果。而 Nastar 等人又认为不同光照条件、稍许遮罩、姿态和面部表情的变化都反映在图像的高频分量上,过多考虑高频分量也会使识别效果对上述条件变得敏感<sup>[8]</sup>。基于以上原因,陈才扣等人提出了一种融合小波变换高低频分量特征的核主元分析方法<sup>[9]</sup>,由于该方法考虑了高频分量对识别时间和效果的影响,只对第 3 层小波变换图像的低频、水平和垂直方向的分量进行 KPCA 分析,然后通过将得

到的本征向量进行特征融合来构造新的人脸鉴别特征,因此获得了较高的分类效果和速度。但是由于该方法是对整幅人脸图像的特征采用统一的方法进行提取与融合,并没有根据人脸特征信息量的分布来抽取其不同局部特征,从而使得抽取的人脸特征并没有达到最优。

基于以上原因,本文考虑到人脸的主要信息量(包括形状和纹理特征)主要集中在人脸的中间区域,而人脸的四周主要对应于人脸的边缘与轮廓,而这些信息正好是实现人脸识别的主要特征。为此本文提出了一种融合小波变换与 KPCA 方法的分块人脸特征抽取算法。该算法在抽取图像特征之前,首先通过对人脸图像进行块状分割和分块小波变换来提取与图像块对应的低频和高频分量,并根据图像块的位置分布,对位于图像边缘的图像块,采用代表人脸轮廓特征的高频分量的平均值作为特征分量,而对位于中间部分的图像块,则采用代表人脸细节特征的低频分量作为特征分量;然后通过对此小波特征分量进行 KPCA 主成分特征抽取和融合来得到最终人脸鉴别特征;最后利用支持向量机分类器进行特征分类与识别。通过对 ORL 和 Yale 标准人脸图像库进行的实验仿真及对比结果表明,本文算法不仅在识别性能和分类速度得到了很大的提高,而且对于人脸光照、姿态和表情变化均具有良好的鲁棒性。

## 2 分块人脸 2 维离散小波变换与特征抽取

### 2.1 2 维离散小波变换的基本概念

基于小波多分辨率图像变换的基本思想是:在选定合适正交小波基的基础上,对图像进行 2 维离散小波变换。设  $I$  为与原始图像  $f(x,y)$  对应的离散信号,  $A$  表示该图像的低频分量,  $D$  表示高频分量,下标表示变换层数,当用 Mallat 金字塔分解算法对该离散图像进行 2 维离散小波变换,就可以得到如下变换系数:

$$A_s = LL_s, D_s = HL_s \cup LH_s \cup HH_s, \quad (1)$$

其中,  $LL_s$  表示第  $s$  层小波变换的低频系数,  $HL_s$ ,  $LH_s$ ,  $HH_s$  则分别表示第  $s$  层小波变换的水平、垂直和对角线 3 个方向的高频系数。图 1 给出了 ORL 人脸库中一幅原始人脸图像在不同层次小波分解后的图像频率分布情况及分解过程示意图。

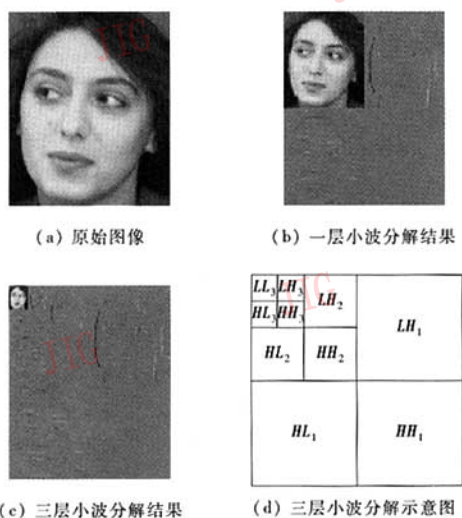


图 1 人脸 2 维离散小波分解  
Fig. 1 Face decomposition with 2-Dimensional DWT

## 2.2 分块人脸 2 维离散小波变换与特征抽取

从图 1 可以看出,一幅人脸图像经过一层小波变换后,被分解成 4 幅不同分辨率和不同空间方向的子图像 ( $LL, HL, LH, HH$ ),其中低频变换系数  $LL$  表示的是原始图像的主要能量分布,其反映了原始图像的平均亮度,对这一部分还可以重复进行多层小波分解;水平、垂直与对角线方向的高频系数  $HL, LH$  和  $HH$  反映了原始图像的边缘轮廓特征。根据前文所述,无论是高频还是低频分量,都代表了能够用于人脸图像有效分类的鉴别特征,舍弃其中任何一部分或者单独依靠某一个分量尽管能降低分类识别的时间复杂度,但也不可避免会带来整体识别性能的下降。为此,本文根据人脸图像的高低频信息分布,提出了一种分块人脸小波变换方法,用来提取人脸图像的局部特征。图 2 给出了人脸分割以及分块人脸小波变换与特征抽取示意图,该算法具体实现过程如下:

(1) 根据人脸图像边缘轮廓与形状纹理特征的位置分布,将待识图像分割成  $m \times n$  个图像块。其中  $m, n$  选择必须合适,一般以完整包含人脸的边缘轮廓的局部特征即可;

(2) 在选择合适小波基的基础上,对分割后的块状图像分别进行 2 维离散小波变换,以提取各块状图像的高频和低频分量;

(3) 对位于图像边缘且包含图像边缘轮廓段的

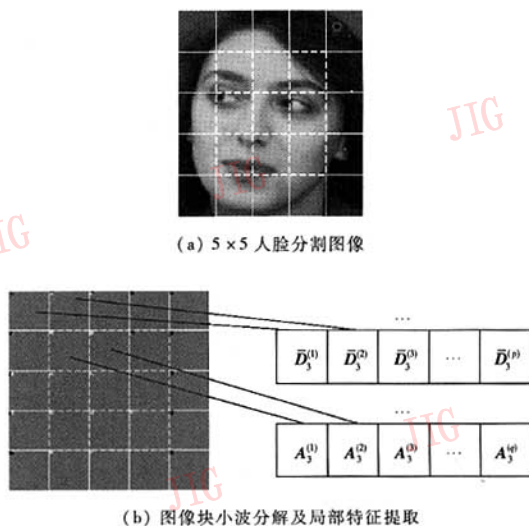


图 2 分块人脸小波分解与局部特征提取  
Fig. 2 Intersected face decomposition and local features extraction

图像块,采用代表人脸边缘轮廓特征的 3 个方向高频分量的平均系数集合  $\bar{D}_s^{(i)}$  作为抽取的人脸边缘的局部高频特征分量,即

$$\bar{D}_s^{(i)} = (HL_s^{(i)} + LH_s^{(i)} + HH_s^{(i)})/3 \quad (2)$$

对位于中间区域的图像块,则直接采用其对应的低频分量作为抽取的形状和纹理特征

$$A_s^{(j)} = LL_s^{(j)} \quad (3)$$

其中,  $s$  为小波变换层数,  $1 \leq i \leq p, 1 \leq j \leq q, p, q$  分别为包含图像边缘轮廓图像块和包含图像细节特征图像块的个数,且两者之和为分割后图像块的总数,即为  $(p+q) = (m \times n)$ 。

算法中,小波变换层数和正交小波基的选取,对人脸鉴别特征的抽取能力和效果具有很大影响,因为尽管小波变换的计算复杂度为常数级,但是小波变换层数的增加不仅会带来小波变换时间复杂度的提高,也会丢失大量的有用鉴别信息。另外,由于不同的正交小波变换基具有不同的频率局部化能力和去冗余相关能力,因而正交小波基的选取对特征向量的最优化提取效果和冗余信息的压缩效果也具有很大影响。周国民等人通过大量的实验分析和比较发现,小波变换层数选择 2 到 3 层,小波基选择双正交小波基或者 B 样条小波,可以同时获得较高的特征抽取速度和效率<sup>[10]</sup>。

### 3 核主成分分析与特征融合

#### 3.1 核主成分分析的基本概念

核主成分分析的基本思想是先通过一个非线性变换  $\Phi$  把输入数据  $X(X \in \mathbf{R}^N)$  映射到一个高维特征空间  $F$  上,  $F = \{\Phi(X): X \in \mathbf{R}^N\}$ , 然后在特征空间  $F$  上执行经典的线性主成分分析, 以便实现输入空间无法实现的线性分类。

给定一组样本数据  $X_t, t = 1, \dots, M, M$  为输入样本数据的个数, 若引入非线性变换  $\Phi$ , 则可把每一个输入样本由输入空间  $\mathbf{R}^N$  向一个高维空间  $F$  进行映射投影, 即  $\Phi: \mathbf{R}^N \rightarrow F, X_t \rightarrow \Phi(X_t)$ , 其中,  $\Phi(X_t)$  为映射到空间  $F$  中的样本矢量。

假设映射后的样本矢量已经被中心化, 即满足其均值为 0, 可表示为  $\sum_{i=1}^M \Phi(X_i) = 0$ , 则映射后样本的协方差矩阵可定义为

$$C = \frac{1}{M} \sum_{i=1}^M \Phi(X_i) \Phi(X_i)^T \quad (4)$$

与该矩阵对应的特征值方程为

$$Cv = \lambda v \quad (5)$$

根据再生核 (theory of reproducing kernel) 理论, 由于在特征空间  $F$  中, 对于任一特征值  $\lambda \neq 0$  所对应的特征向量  $v$  一定位于由  $\{\Phi(X_1), \dots, \Phi(X_M)\}$  张成的空间内, 因而存在向量  $\alpha_i (i = 1, \dots, M)$ , 并且有

$$v = \sum_{i=1}^M \alpha_i \Phi(X_i) \quad (6)$$

$M \times M$  阶核矩阵  $K$  定义为

$$K_{i,j} = K(X_i, X_j) = \Phi(X_i)^T \Phi(X_j) \quad (7)$$

将式(4)、式(6)、式(7)代入式(5)后, 可得以下全部用核函数表示的特征值方程

$$K\alpha = M\lambda\alpha = \hat{\lambda}\alpha \quad (8)$$

这样就求解式(5)特征向量  $v$  的问题转换成求解式(8)特征值方程的特征向量  $\alpha$  的问题。设该特征值方程的解由大到小为:  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_M \geq 0$ , 对应的特征向量为  $\alpha_1, \alpha_2, \dots, \alpha_M$ , 对应于式(5)的特征矢量为  $v_1, v_2, \dots, v_M$ , 并假设  $\lambda_M$  为最后 1 个非零特征值, 则从特征矢量的正交规一条件

$$v_g^T v_r = \delta_{g,r}, \forall g, r = 1, 2, \dots, M \quad (9)$$

就可以推导出关于特征向量  $\alpha_i$  的正交规一条件, 即

$$\hat{\lambda} \alpha_g^T \alpha_r = \delta_{g,r}, \forall g, r = 1, 2, \dots, M \quad (10)$$

进而由式(8)与条件式(10)就可以得出特征向量的唯一解  $\{\alpha_i, i = 1, 2, \dots, M\}$ 。于是对输入空间的任一样本  $X$ , 即可求其在高维空间  $F$  中  $\Phi(X)$  的第  $k$  个主成分, 即它在第  $k$  个主成分特征矢量  $v_k$  方向上的投影

$$\begin{aligned} y_k &= (v_k \cdot \Phi(X)) = \sum_{i=1}^M \alpha_i^{(k)} (\Phi(X_i) \cdot \Phi(X)) \\ &= \sum_{i=1}^M \alpha_i^{(k)} K(X_i, X) \end{aligned} \quad (11)$$

由此可见, KPCA 方法不仅具有与线性 PCA 方法相同的数学与统计特性, 如各主元分量互不相关、主元分量可以表示样本数据的最大方差等, 而且通过引入核函数, 还避免了在高维特征空间  $F$  中计算内积的不便。文献[3]实验证明, 在达到同样分类性能的前提下, KPCA 方法所需的主元个数要远少于线性 PCA 方法, 并且与其他非线性特征抽取方法相比, 由于 KPCA 方法不需要解决非线性优化问题, 而只涉及到矩阵的特征值分解计算, 因而可以有效提高特征抽取的效率与速度。

#### 3.2 小波特征 KPCA 抽取与融合

对上述获得的图像块小波特征进行 KPCA 特征抽取。设对于表示边缘轮廓特征的小波分解第  $s$  层局部高频特征分量  $\bar{D}_i^{(p)}$ , 其抽取的核主成分分量为  $h_i^{(p)}$ , 而对于表示人脸形状和纹理特征的低频分量  $A_i^{(q)}$ , 其抽取的核主成分分量为  $l_i^{(q)}$ , 即满足

$$h_i^{(p)} = \left( \sum_{i=1}^M \alpha_i^{(k)} (\Phi(\bar{D}_i^{(1)}) \cdot \Phi(\bar{D}^{(1)})) \right), \dots, \sum_{i=1}^M \alpha_i^{(k)} (\Phi(\bar{D}_i^{(p)}) \cdot \Phi(\bar{D}^{(p)})) \quad (12)$$

$$l_i^{(q)} = \left( \sum_{i=1}^M \alpha_i^{(k)} (\Phi(A_i^{(1)}) \cdot \Phi(A^{(1)})) \right), \dots, \sum_{i=1}^M \alpha_i^{(k)} (\Phi(A_i^{(q)}) \cdot \Phi(A^{(q)})) \quad (13)$$

然后分别对高低频主成分分量进行特征融合, 并利用串行组合形式构造以下最终鉴别特征矢量

$$z = (\beta_1 h_i^{(p)}, \beta_2 l_i^{(q)})^T \quad (14)$$

其中,  $\beta_1, \beta_2$  为融合系数, 且满足  $\beta_1 + \beta_2 = 1$ , 同时为了抑制光照、姿态和表情变化对边缘轮廓的影响, 并突出人脸的形状和纹理细节局部特征, 一般取  $\beta_1 < \beta_2$ 。

### 4 算法实现

根据上述对各种方法的讨论, 本文提出的人脸

特征提取和分类识别算法的具体实现步骤如下：

(1) 在对输入训练样本图像分块的基础上,对每个块状人脸图像进行三层正交小波分解,并根据式(2)和式(3)提取每个图像块对应的组合小波特征;

(2) 利用式(11)~式(13)分别对组合小波特征进行 KPCA 特征提取来获得特征空间上每个图像块的核主分量特征;

(3) 根据式(14)对每个图像块的核主成分分量进行串行特征融合来构造最终人脸鉴别特征;

(4) 利用支持向量机分类器对人脸融合特征进行分类识别。

图 3 给出了本文算法的结构框图。




图 3 本文算法的结构框图

Fig.3 Algorithm flowchart of this paper

### 5 实验结果与分析

为验证本文算法的效果,选取了 ORL 人脸图像库和 Yale 人脸图像库中的测试图像进行了实验。其中 ORL 人脸库有 40 类人脸,每一类人脸有 10 幅图像,分辨率为  $92 \times 112$ ,都为正面图像,略有尺度和旋转变化;Yale 人脸库包含 15 类人脸,每类人脸有 11 幅图像,分辨率为  $120 \times 91$ ,图像背景较为复杂,且光照条件、人的脸部表情和姿态也有着很大程度的变化。根据上述对实验条件的讨论,实验中,首先对人脸图像进行  $5 \times 5$  块状分割,小波变换层数  $s$  选择为 3,小波基选取了阶数为分析 9 阶和合成 7 阶的双正交小波滤波器组,滤波器系数列于表 1。SVM 分类采用“一对多”的组合策略<sup>[11]</sup>,即将所有类别中任意一类人脸与剩余其余类别组合构建一个 SVM 二值分类器,分类器的误差惩罚因子  $C$  选择为 100。KPCA 特征抽取和 SVM 分类中所用的核函数均选择参数  $\gamma = 1$  的径向基核函数  $K(X, Y) = \exp(-\gamma \|X - Y\|^2/2)$ 。特征融合系数选择为  $\beta_1 = 0.42, \beta_2 = 0.58$ 。

表 1 双正交小波滤波器组的系数

Tab.1 Coefficients of biorthogonal wavelet filter group

$n$	0	$\pm 1$	$\pm 2$	$\pm 3$	$\pm 4$
$c[n]$	0.852 699	0.377 403	-0.110 624	-0.023 849	0.037 828
$\tilde{c}[n]$	0.788 486	0.418 029	-0.040 689	-0.064 539	0

实验中,为了验证本文算法的快速性以及对本样本随机选取的鲁棒性,本文首先从每一类人脸图像中随机取出 5 幅图像作为训练样本,将剩余的图像作为测试样本,但对图像的尺寸和灰度不进行任何变化;然后在 PIV 1.4GHz,256M 硬件环境,Visual C++6.0 实验平台下对本文算法进行 100 次分类识别实验,将 100 次实验结果的平均值作为最终识别结果。同时为了说明本文算法的有效性,本文还将该结果与文献[6,9]所提算法 100 次实验所得正确识别率的平均值进行了比较(对比结果如表 2 所示)。另外为了验证小波变换层数对识别结果以及特征抽取、分类时间的影响,本文针对同样数量的训练样本和测试样本,在分别进行 1~3 层离散小波变换和 KPCA 特征抽取的情况下,进行了和上述实验同样次数的分类识别,实验结果见表 3(表中数据为平均值)。

表 2 不同小波特征抽取下结合 KPCA 方法的 SVM 平均正确识别率

Tab.2 Average recognition results with KPCA and SVM of different wavelet features extraction methods

人脸库	正确识别率(%)		
	文献[6]算法	文献[9]算法	本文算法
ORL 人脸库	93.59	95.72	98.52
Yale 人脸库	89.23	92.46	96.41

从表 2 实验结果可以看出,小波变换所得到的高频和低频分量各有不同的作用,舍弃其中的任何一部分或者单独依靠某一个分量进行识别都不能获得令人满意的效果。本文采用分块人脸小波变换的方法来提取人脸图像的局部特征,由于充分考虑了人脸高低频分量的位置分布,对位置不同的图像块提取不同的鉴别分量,从而最大限度地提取了用于人脸分类的有效局部特征。另外,本文算法还以表示人脸轮廓边缘高频分量的融合特征作为部分鉴别特征,从而有效地抑制了光照、人脸姿态以及背景变化对人脸轮廓边缘特征抽取的影响,并且通过采用支持向量机进行特征分类识别,使得在 ORL 人脸库上

的平均识别正确率可以达到 98% 以上,在图像质量较差的 Yale 人脸库上的识别正确率仍然可以达到 96.41%,识别性能明显优于 KPCA 方法以及文献 [6],[9]中传统的基于融合小波特征的 KPCA 方法。

从表 3 可以看出,以双正交小波滤波器组作为变换小波基,采用人脸三层小波变换的高低频分量作为识别特征,不仅能够对人脸的冗余信息进行有效的压缩,而且可以实现有效鉴别特征的最优化提取,但是如果继续进行小波分解,则不仅会增加算法的复杂度,同时也会丢失大量有用的鉴别信息,从而造成识别率的下降。表 3 还给出了不同算法在两个人脸库上的特征抽取与分类识别时间的对比结果,从表 3 数据可以看出,由于本文抽取的小波特征向量的维数只有原始图像的 1/64,最终的人脸鉴别特征保持在 150 维左右,这与原始人脸图像高达上十万的特征维数相比,降低了将近两个数量级,也使构造特征空间上的核矩阵所耗费的时间复杂度大幅度降低,从而使得本文算法在两个人脸库上的平均特征抽取速度达到了传统 KPCA 方法的 10 倍左右,同时结合支持向量机进行分类识别,获得了较高的分类速度和效率,已完全达到了人脸图像实时分类识别的要求。

表 3 本文算法在不同小波变换层数下结合 KPCA 方法的实验结果

Tab.3 Average experimental results based on KPCA and different layer wavelet transform

人脸库	特征抽取方法	识别率 (%)	特征抽取时间 (s)	分类时间 (s)	总时间 (s)
ORL 人脸库	KPCA	92.26	341.74	31.43	373.17
	1-level DWT + KPCA	93.82	120.52	30.27	150.79
	2-level DWT + KPCA	95.74	53.37	29.61	82.98
	3-level DWT + KPCA	98.52	34.06	29.37	63.43
Yale 人脸库	KPCA	86.29	402.16	29.92	431.92
	1-level DWT + KPCA	91.63	149.85	29.53	179.38
	2-level DWT + KPCA	95.58	74.28	29.06	103.34
	3-level DWT + KPCA	96.41	47.63	28.35	75.98

另外,为了说明本文算法对人脸训练样本和测试样本随机抽取的稳定性,还在 ORL 人脸库上对表 3 所列特征抽取方法在随机抽样和不同实验次数下的识别率的总体方差进行了统计,统计结果如图 4 所示。从图 4 可以看出,本文算法在不同实验次数下的识别率总体方差均保持在 1.5 以下,而且曲

线走向比较平稳,这说明对于任意样本的抽样方法和实验次数,本文算法均能获得较高的识别率,并且对样本随机选取的差异程度具有较强的适应性和稳定性。

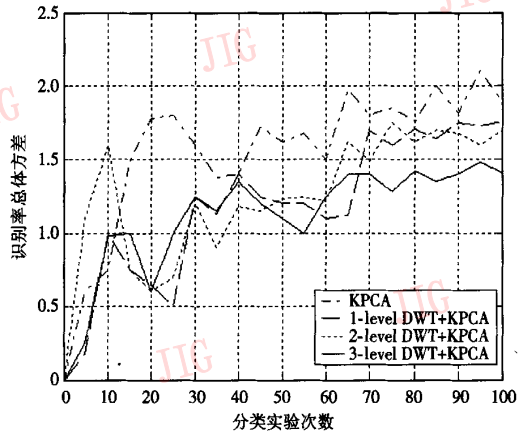


图 4 ORL 人脸库上不同分类实验次数下的识别率总体方差分布图

Fig.4 Population variance of recognition rate of different experimental times on ORL database

## 6 结 论

本文在对小波变换与 KPCA 方法的人脸特征的抽取能力进行分析的基础上,提出了一种融合小波变换与 KPCA 方法的分块人脸特征抽取算法。该算法先通过对人脸图像进行分块小波变换来提取与图像块对应的低频和高频分量,并根据图像块的位置分布采用不同的分量作为小波抽取特征;然后通过对此小波特征分量进行 KPCA 特征抽取与融合来得到最终的人脸鉴别特征;最后利用支持向量机分类器进行特征分类与识别。由 ORL 和 Yale 标准人脸图像库的实验仿真及对比结果表明,本文算法对于光照、人脸姿态以及表情变化具有良好的鲁棒性,在保证识别性能的同时,还获得了较高的分类速度。

### 参考文献 (References)

- 1 Turk M, Pentland A. Eigenfaces for recognition [J]. Journal of Cognitive Neuroscience, 1991, 3(1): 71 ~ 86.
- 2 Belhumeur P N, Hespanha J P, Kriegsmann D J. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1997, 19(7): 711 ~ 720.
- 3 Scholkopf B, Smola A, Muller K. Nonlinear component analysis as a kernel eigenvalue problem [J]. Neural Computation, 1998, 10(5):

- 1299 ~ 1319.
- 4 Baudat G, Anouar F. Generalized discriminant analysis using a kernel approach[J]. *Neural Computation*, 2000, **12**(10): 2385 ~ 2404.
  - 5 Moghaddam B. Principal manifolds and probabilistic subspaces for visual recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(6): 780 ~ 788.
  - 6 Gao Xi-qi, Zhou Hong-xiang, He Zhen-yang. Face recognition based on wavelet transform and kernel principal component analysis[J]. *Journal of Southeast University*, 1996, **26**(2): 137 ~ 141. [高西奇, 周洪祥, 何振亚. 基于小波变换的主元分析人脸图象识别[J]. *东南大学学报*, 1996, **26**(2): 137 ~ 141.]
  - 7 Xie Yong-hua, Fu De-sheng, Ren Wei-hua. A fractal image coding algorithm research based on wavelet transformation[J]. *Journal of Image and Graphics*, 2003, **7**(8): 839 ~ 842. [谢永华, 傅德胜, 任卫华. 一种基于小波变换的图像分形编码压缩算法的研究[J]. *中国图象图形学报*, 2003, **7**(8): 839 ~ 842.]
  - 8 Nastar C, Ayache N. Frequency-based non-rigid motion analysis[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996, **18**(11): 1067 ~ 1079.
  - 9 Chen Cai-kou, Wang Zheng-qun, Yang Jing-yu. A fast kernel principal component analysis technique based on wavelet feature[J]. *Computer Engineering and Applications*, 2004, **22**(40): 45 ~ 47. [陈才扣, 王正群, 杨静宇. 基于小波特征的快速核主分量分析技术[J]. *计算机工程与应用*, 2004, **22**(40): 45 ~ 47.]
  - 10 Zhou Guo-min, Chen Yong, Li Guo-jun. Two keys to the application of wavelet transform in human face recognition[J]. *Journal of Zhejiang University(Science Edition)*, 2005, **32**(1): 34 ~ 38. [周国民, 陈勇, 李国军. 人脸识别中应用小波变换的两个关键问题[J]. *浙江大学学报*, 2005, **32**(1): 34 ~ 38.]
  - 11 Weston J, Watkins C. Multi-class support vector machines[R]. Technical Report CSD-TR-98-04 in Royal Holloway University of London, 1998.