

# 基于 KDA/GSVD 和支持向量机的人耳识别

赵海龙<sup>1</sup> 穆志纯<sup>1</sup> 张霞<sup>1,2</sup> 敦文杰<sup>1</sup>

(北京科技大学信息工程学院 北京 100083)<sup>1</sup> (河北经贸大学计算机中心 石家庄 050061)<sup>2</sup>

**摘要** 在高维、小样本的情况下使用 Fisher 线性鉴别分析的特征提取方法存在病态奇异问题,学者们提出了许多解决此问题的方法。针对小样本问题,并通过对现有人耳识别方法的研究,提出了一种利用 KDA/GSVD 算法对图像数据进行降维,运用 SVM 分类器对样本进行判别的人耳识别方法。此外,还对线性判别分析、广义奇异值分解和支持向量机的基本理论等内容做了简要介绍。实验证明,KDA/GSVD 很好地解决了由于小样本的问题而导致的 LDA 算法中类内离散度矩阵不可求逆的问题,把它与支持向量机有机地结合起来,构成了一种有效的人耳识别新方法。

**关键词** 人耳识别,线性判别分析,广义奇异值分解,KDA/GSVD,支持向量机

中图分类号 TP391 文献标识码 A

## Ear Recognition Using KDA/GSVD and SVM

ZHAO Hai-long<sup>1</sup> MU Zhi-chun<sup>1</sup> ZHANG Xia<sup>1,2</sup> DUN Wen-jie<sup>1</sup>

(School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China)<sup>1</sup>

(Computer Center, Hebei University of Economics and Business, Shijiazhuang 050061, China)<sup>2</sup>

**Abstract** Ear recognition is one of important branches of biometrics. We proposed a new ear recognition method which uses KDA/GSVD method to reduce image dimensions and support vector machines as classifier. The experimental results on the USTB-77 ear database show that the new method can overcome the singularity problem of covariance matrices that represent the scatter within and between clusters and perform well in accuracy simultaneously.

**Keywords** Ear recognition, Linear discriminant analysis, Generalized singular value decomposition, KDA/GSVD, Support vector machines

### 1 引言

随着社会的发展,对身份验证的需求也日益增加,许多领域都在不断地对身份验证提出新的要求和挑战。生物特征是人的内在属性,具有较强的自身稳定性和个体差异性,可以作为身份认证的较好依据。人耳作为人的生物特征之一,除了具备普遍性和唯一性等特点之外,与人脸等其它生物特征识别技术相比,还具有不易受表情和化妆影响、不易损伤以及图像颜色分配一致等独特优势,因此人耳识别技术近年来已成为计算机视觉和模式识别领域中的一个前沿课题。

Fisher 线性判别(FLD),也称线性判别分析(LDA),是一种在模式识别领域应用很广的一种算法,主要用作特征提取和降维。Fisher 准则函数定义为

$$J_F(G) = \frac{G^T S_b G}{G^T S_w G} \quad (1)$$

FLD 的基本思想是求解鉴别矢量构成投影矩阵  $G$ ,将样本映射到低维空间,使样本特征在低维空间的类间散度  $S_b$  最大且类内散度  $S_w$  最小(即最大化  $J_F$ ),以便得到可分性更好的鉴别特征。不难证明,使  $J_F$  最大化的  $G$  同时也满足

$$S_b G = \lambda S_w G \quad (2)$$

当  $S_w$  为非奇异(即可求逆)时,式(2)可变换为

$$\lambda G = S_w^{-1} S_b G \quad (3)$$

因此,问题就转化为求矩阵  $S_w^{-1} S_b$  的特征值和特征向量,则  $\lambda$  是其特征值,  $G$  是对应的特征向量<sup>[1]</sup>。然而在人耳识别中,由于存在小样本问题(即样本向量的维数远大于样本的数目),使得类内散度矩阵  $S_w$  为奇异的、不可求逆,这导致人们无法直接用求  $S_w^{-1} S_b$  的特征向量的方法获得投影矩阵  $G$ 。

近年来,有的学者提出了一种称为 KDA/GSVD 的降维算法。该算法是对 LDA/GSVD 算法的进一步扩展,不仅解决了小样本情况下古典 LDA 算法中  $S_w$  的奇异性问题,而且通过引入核函数,增强了对非线性可分样本的处理能力。

支持向量机(Supproted Vector Machine)简称 SVM,是 Vapnik 与其合作者在 AT&T 贝尔实验室研究成功的一种机器学习算法,自 1992 年首次被提出以来,得到了很大的发展。支持向量机是基于结构风险最小化原理的统计学习方法,适用于小样本分类问题<sup>[2]</sup>。

本文共分为 5 个部分:第 2 部分简要介绍了 LDA 和 GSVD 的基本概念;第 3 部分描述 KDA/GSVD 算法的计算步

到稿日期:2008-03-20 本文受国家自然科学基金(基于人耳人脸信息融合的多模态生物特征识别技术,60573058),国家自然科学基金(人耳识别技术研究,60375002)资助。

赵海龙(1976—),男,博士研究生,研究方向为模式识别和图像处理;穆志纯(1952—),男,教授,博士生导师,主要研究方向为模式识别、生物特征识别、过程控制、复杂系统的建模和控制。

骤;第4部分阐述支持向量机的相关概念;第5部分详细说明了使用KDA/GSVD+SVM的方法对人耳图像进行降维和识别的过程、步骤,并给出了实验的结果。

## 2 LDA和GSVD的基本概念

### 2.1 LDA

设 $N$ 个 $D$ 维的样本向量 $a_k \in i^{D \times 1} \{k=1, \dots, N\}$ 来自 $C$ 个不同的类别 $\{L_1, \dots, L_C\}$ ,每个类别中样本的个数是 $N_i \{i=1, 2, \dots, C\}$ , $A = \{a_1, \dots, a_N\}$ 是由样本向量 $a_k$ 组成的矩阵,而 $S_w, S_b, S_t$ 分别表示类内散度矩阵、类间散度矩阵和总离散度矩阵,那么

$$S_b = \sum_{i=1}^C N_i (m_i - m)(m_i - m)^T = H_b H_b^T \quad (4)$$

$$S_w = \sum_{i=1}^C \sum_{a \in L_i} (a - m_i)(a - m_i)^T = H_w H_w^T \quad (5)$$

$$S_t = \sum_{i=1}^N (a_i - m)(a_i - m)^T = H_t H_t^T \quad (6)$$

$$S_t = S_w + S_b \quad (7)$$

其中 $m_i$ 代表各类样本的类内均值, $m$ 代表样本的总体均值。散度矩阵与协方差矩阵相似,都是半正定的。正像在许多信号处理问题中协方差矩阵分解为一个矩阵与其转置的乘积一样,离散度矩阵也分解成其“平方根”因子乘积的形式<sup>[3,4]</sup>:

$$H_b = [\sqrt{N_1}(m_1 - m), \dots, \sqrt{N_C}(m_C - m)] \in i^{D \times C} \quad (8)$$

$$H_w = [A_1 - m_1 e_1^T, A_2 - m_2 e_2^T, \dots, A_C - m_C e_C^T] \in i^{D \times N} \quad (9)$$

$$H_t = [a_1 - m, \dots, a_N - m] \in i^{D \times N} \quad (10)$$

这里 $e_i \in i^{N_i \times 1} \{i=1, \dots, C\}$ 的全部元素值等于1,而 $A_i \in i^{D \times N_i} \{i=1, \dots, C\}$ 表示样本矩阵 $A$ 中属于第 $i$ 类的所有列向量组成的矩阵。

### 2.2 GSVD

Van Loan<sup>[5]</sup>在下面的定理中介绍了广义奇异值分解(Generalized Singular Value Decomposition, GSVD)的概念:

**定理1** 设给定两个矩阵 $K_A \in i^{p \times m} (p \geq m)$ 和 $K_B \in i^{n \times m}$ ,那么一定存在正交矩阵 $U \in i^{p \times p}$ 和 $V \in i^{n \times n}$ 以及非奇异矩阵 $X \in i^{m \times m}$ 满足

$$U^T K_A X = \text{diag}(\alpha_1, \dots, \alpha_m) \quad (11)$$

$$V^T K_B X = \text{diag}(\beta_1, \dots, \beta_m) \quad (12)$$

这里 $q = \min(n, m)$ , $\alpha_i \geq 0 (1 \leq i \leq m)$ 且 $\beta_i \geq 0 (1 \leq i \leq q)$ 。

□

当 $K_A$ 的维数不满足上述假设条件时,公式(11)、(12)不成立。为此Paige和Saunders<sup>[6]</sup>提出了一个更加通用的公式,该公式可用于任何两个具有相同列数的矩阵对。

**定理2** 设给定两个矩阵 $K_A \in i^{p \times m} (p \geq m)$ 和 $K_B \in i^{n \times m}$ ,那么对于 $K = \begin{pmatrix} K_A \\ K_B \end{pmatrix}$ 和 $t = \text{rank}(K)$ ,则一定存在4个正交矩阵 $U \in i^{p \times p}$ , $V \in i^{n \times n}$ , $W \in i^{t \times t}$ 和 $Q \in i^{m \times m}$ 满足

$$U^T K_A Q = \begin{pmatrix} \underbrace{W^T R}_t & \underbrace{0}_{m-t} \\ & \underbrace{0}_{m-t} \end{pmatrix} \quad (13)$$

$$V^T K_B Q = \begin{pmatrix} \underbrace{W^T R}_t & \underbrace{0}_{m-t} \\ & \underbrace{0}_{m-t} \end{pmatrix} \quad (14)$$

这里

$$\sum_{p \times t} A = \begin{pmatrix} I_A & & \\ & D_A & \\ & & O_A \end{pmatrix}, \sum_{n \times t} B = \begin{pmatrix} I_B & & \\ & D_B & \\ & & O_B \end{pmatrix}, R \in i^{t \times t}$$

是非奇异的并且它的奇异值等于 $K$ 的非零奇异值。矩阵 $I_A \in$

$i^{r \times r}$ 和 $I_B \in i^{(t-r) \times (t-r)}$ 都是单位矩阵且 $r = \text{rank} \begin{pmatrix} K_A \\ K_B \end{pmatrix} - \text{rank}(K_B)$ , $s = \text{rank}(K_A) + \text{rank}(K_B) - \text{rank} \begin{pmatrix} K_A \\ K_B \end{pmatrix}$ , $O_A \in i^{(p-r) \times (p-r)}$ 和 $O_B \in i^{(n-t+r) \times r}$ 是零矩阵, $D_A = \text{diag}(\alpha_{r+1}, \dots, \alpha_{r+s})$ 和 $D_B = \text{diag}(\beta_{r+1}, \dots, \beta_{r+s})$ 满足 $1 > \alpha_{r+1} \geq \dots \geq \alpha_{r+s}$ , $0 < \beta_{r+1} \leq \dots \leq \beta_{r+s}$ 和 $\alpha_i^2 + \beta_i^2 = 1 (i=r+1, \dots, r+s)$ 。

广义奇异值分解的公式可改写成下面的形式:

$$U^T K_A X = (\sum_A, 0), V^T K_B X = (\sum_B, 0) \quad (15)$$

其中 $X_{m \times m} = Q \begin{pmatrix} R^{-1} W & 0 \\ 0 & I \end{pmatrix}$ 。由式(15)不难看出 $K_A = U (\sum_A, 0) X^{-1}$ , $K_B = V (\sum_B, 0) X^{-1}$ ,由此得

$$K_A^T K_A = X^{-T} \begin{pmatrix} \sum_A^T \sum_A & 0 \\ 0 & 0 \end{pmatrix} X^{-1} \quad (16)$$

$$K_B^T K_B = X^{-T} \begin{pmatrix} \sum_B^T \sum_B & 0 \\ 0 & 0 \end{pmatrix} X^{-1} \quad (17)$$

设 $\alpha_i = 1, \beta_i = 0 (i=1, \dots, r)$ 和 $\alpha_i = 0, \beta_i = 1 (i=r+s+1, \dots, t)$ ,则对于 $1 \leq i \leq t$ ,必有

$$\beta_i^2 K_A^T K_A x_i = \alpha_i^2 K_B^T K_B x_i \quad (18)$$

其中 $x_i$ 代表矩阵 $X$ 的第 $i$ 列。对于 $X$ 的其余 $m-t$ 列, $K_A^T K_A x_i$ 和 $K_B^T K_B x_i$ 都为零,所以当 $t+1 \leq i \leq m$ 时,式(18)满足任意的 $\alpha_i$ 和 $\beta_i$ 。 $X$ 的列向量称为矩阵对 $(K_A, K_B)$ 的广义奇异向量。对于广义特征值(即 $\alpha_i/\beta_i$ 系数),其中 $r$ 个是无穷大, $s$ 个是有限的非零值, $t-r-s$ 个是零值。

## 3 KDA/GSVD算法

Peg Howland<sup>[7]</sup>等提出的LDA/GSVD算法已经能够较好地解决高维、小样本条件下使用Fisher LDA进行特征提取存在的病态奇异问题;C. H. Park<sup>[8]</sup>等在LDA/GSVD算法的基础上进一步提出了KDA/GSVD算法,通过引入核函数的方法增强了对线性不可分的样本数据的处理能力。KDA/GSVD算法可描述如下:

假设有样本矩阵 $A = [a_1, \dots, a_n] \in i^{m \times n}$ 和核函数 $\kappa$ ,向量 $a_k \in i^{m \times 1} \{k=1, \dots, n\}$ 代表各个样本向量, $r$ 为样本的类别数, $n$ 为样本总数, $N_i \{i=1, \dots, r\}$ 表示第 $i$ 个类别的所有样本组成的集合。对任一给定的输入向量 $z \in i^m$ ,我们要通过在特征空间中进行广义奇异值分解从而找到向量 $z$ 的 $r-1$ 维表示 $y \in i^{(r-1) \times 1}$ ,这里特征空间由特征映射 $\Phi$ 定义且满足 $\kappa(a_i, a_j) = \langle \Phi(a_i), \Phi(a_j) \rangle$ 。

1)根据式(19)、(20)分别计算 $K_b$ 和 $K_w$ :

$$K_b = [b_{ij}]_{(1 \leq i \leq n, 1 \leq j \leq r)} \quad (19)$$

$$b_{ij} = \sqrt{n_j} \left( \frac{1}{n_j} \sum_{s \in N_j} \kappa(a_i, a_s) - \frac{1}{n} \sum_{s=1}^n \kappa(a_i, a_s) \right)$$

$$K_w = [w_{ij}]_{(1 \leq i \leq n, 1 \leq j \leq n)} \quad (20)$$

$$w_{ij} = \kappa(a_i, a_j) - \frac{1}{n} \sum_{s \in N_j} \kappa(a_i, a_s)$$

2)对矩阵 $(K_b^T, K_w^T)$ 进行广义的奇异值分解:

$$U^T K_b^T X = [\Gamma_b \ 0] \text{和} V^T K_w^T X = [\Gamma_w \ 0]$$

3)取矩阵 $X$ 的前 $r-1$ 列赋值给 $G$ ;

4)对任一给定的输入向量 $z \in i^m$ ,其降维后的向量 $y$ 可

$$\text{表示为} y = G^T \begin{bmatrix} \kappa(a_1, z) \\ \vdots \\ \kappa(a_n, z) \end{bmatrix} \in i^{(r-1) \times 1}.$$

## 4 支持向量机

支持向量机(Support Vector Machines, SVM)是 Vapnik 等人在统计学习理论上提出的一种结构风险最小化的机器学习算法。对于一个两类模式识别问题,训练样本集为  $(x_i, y_i), x_i \in \mathbb{R}^d \{i=1 \dots l\}, y_i \in \{+1, -1\}$ , 支持向量机的目标是要找到一个最优的分割超平面  $H: w \cdot x + b = 0$ , 该超平面能最大程度地把两类训练样本分开, 同时使每类样本到它的距离尽可能地大, 即超平面具有尽可能大的边缘<sup>[9]</sup>。

在实际应用中, 绝大多数问题是非线性可分的, 甚至是不可分的。在引入核技巧之后, 非线性支持向量机可以描述为下面的最优化问题:

$$\max_{\alpha} L_D = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (21)$$

$$s. t. \sum_{i=1}^l \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \quad \forall i \quad (22)$$

对于新的样本  $x_{new}$ , 其分类规则函数为

$$f(x_{new}) = \text{sign}(\sum_{i=1}^l \alpha_i y_i K(x_i, x_j) + b)$$

其中  $x$  是训练样本,  $y$  是样本的类标,  $\alpha$  是拉格朗日因子,  $K$  为核函数,  $C$  为惩罚因子。

常用的核函数有 4 个, 它们分别是线性核函数、多项式核函数、径向基(Radial Basis Function)核函数和 Sigmoid 核函数。

## 5 实验过程和结果

### 5.1 人耳库介绍

在本实验中, 笔者使用的是 USTB(77)人耳图像库。该库包括 308 幅人耳图像, 共 77 人, 每人 4 幅灰度图像, 图像大小为  $300 \times 400$  像素, 如图 1 所示。(a)为室内正常光照条件下的图像, (b)为头部逆时针旋转  $30^\circ$  拍摄的人耳图像, (c)为头部顺时针旋转  $30^\circ$  拍摄的人耳图像, (d)为光照减弱时图像。这里主要考虑室内光照变化情况<sup>[10]</sup>。需要指出的是, 图 1 是人耳库中的原始图像, 还没有经过检测、分割以及归一化等过程。




图 1 人耳图像实例

### 5.2 分类器设计

支持向量机本质上是两类模式识别问题设计的, 但人耳识别属于多类模式问题, 所以必须扩展(两类)支持向量机来处理多类问题。由两类 SVM 构建多类 SVM 的方法基本上都是基于分解策略的, 主要有显式分解和隐式分解。基于隐式分解策略的方法对应的优化问题的规模和难度都要远远大于基于显式分解策略的方法, 所以实际应用中大多采用显式分解策略。

基于显式分解策略的方法主要有两种: 一对多(One-against-Rest)和一对一(One-against-One)。在 One-against-Rest 方法中, 一个  $k$  类问题被分解为  $k$  个子两类问题, 每个两类分类器负责把一类样本和其他类别的所有样本分开; 而在

One-against-One 方法中, 一个  $k$  类问题被分解为  $\frac{k(k-1)}{2}$  个子两类问题, 每两个类别之间都由一个两类分类器负责分开。笔者在实验中选择了 One-against-Rest 方法。

这里采用径向基(RBF, 如式(23)所示)函数作为核函数, 因为它定义的是空间两点之间欧式距离的单调减函数, 即空间两点之间距离越大函数的取值越小。这使它更加符合特征提取的要求, 即不同类别的样本在特征空间的距离应尽可能地大而同一类别的样本之间的距离应尽可能地小。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (23)$$

### 5.3 实验过程

本系统由图像预处理、特征提取、分类器设计和分类决策 4 个部分组成, 如图 2 所示。具体的试验步骤总结如下:



图 2 人耳识别系统框图

(1)首先对人耳图像进行预处理, 包括人耳检测和分割、直方图均衡以及归一化。人耳检测和分割得到的图像质量, 其好坏将直接影响到最后的分类结果; 直方图均衡能降低光照对图像的影响, 提高对比度; 归一化又可分为几何归一化和尺寸归一化, 此处把样本图像的大小统一调整为  $25 \times 50$  (宽  $\times$  高)。

(2)训练集和测试集中每个样本经过图像预处理后, 再拉伸为一个列向量, 从而可以形成训练样本矩阵  $X_{train}$  (即 KDA/GSVD 算法中的矩阵  $A$ ) 和测试样本矩阵  $X_{test}$ ; 本实验中采用 1, 2, 3 组图像作为训练集, 采用第 4 组图像作为测试集。训练集中样本的类别是已知的, 用来对计算机训练进而得到判别模型; 测试集用来测试最终的识别率, 测试集中样本的类别对研究者是已知的, 但并不输入计算机。

(3)利用训练样本矩阵  $X_{train}$  按照 KDA/GSVD 可计算出原始的样本向量  $z$  与降维后的向量  $y$  之间的映射关系, 即

$$y = G^T \begin{bmatrix} \kappa(a_1, z) \\ \vdots \\ \kappa(a_n, z) \end{bmatrix}$$

中的原始向量进行特征提取, 得到  $X'_{train}$  和  $X'_{test}$ 。

(4)矩阵  $X'_{train}$  和  $X'_{test}$  中的每个列向量就是对样本向量进行特征提取的结果, 把  $X'_{train}$  及其列向量(样本)的类别标号输入到 SVM 分类器进行训练, 从而得到测试模板, 最后利用测试模板判定  $X'_{test}$  中各列向量(样本)的类别。

### 5.4 实验结果

本实验的硬件环境为 AMD64 位双核处理器, 内存 1G; 软件环境为 Windows XP 和 Matlab 6.5。本文方法与其它方法的识别率比较如表 1 所列。

表 1 不同方法的识别率比较

识别方法	人耳库	识别率
主元分析法(PCA)	USTB(77)	76.6%
外耳形状特征和内耳结构特征 <sup>[11]</sup>	USTB(77)	85.7%
LDA/GSVD+NN	USTB(77)	96.1%
PCA+LDA	USTB(77)	98.7%
KDA/GSVD+SVM	USTB(77)	100%

从实验结果可以看出,KDA/GSVD与SVM相结合的方法,其识别率达到了100%,明显高于表中其它的方法。原因可分析如下:主元分析的目标是寻找在最小均方差意义下最能够代表原始数据的投影方法,它以所有样本的最优重建为目的,计算过程中去掉了信号表示无用的信息,但这些信息对信号分类则可能是有用的,因此PCA对于分类并不是最优的;外耳形状特征和内耳结构特征是一种基于几何特征的识别方法,准确地检测、定位特征点以及合理地提取特征向量是这类方法需要仔细研究的问题;本文方法比LDA/GSVD+NN(最近邻分类器)和PCA+LDA(Fisherfaces)的识别率略高,因为人耳识别是一个非线性问题,核函数的引入使识别率得到了进一步的提高。

实验证明本文提出的KDA/GSVD+SVM是一种非常有效的人耳识别方法,具有广阔的应用前景。

### 参 考 文 献

[1] 钟路,潘昊,封筠,等. 模式识别[M]. 武汉:武汉大学出版社,2006  
 [2] Heisele B, Ho P, Wu J, et al. Face recognition: component based versus global approaches. *Comput Vision Image Understanding*, 2003, 91:6  
 [3] Speiser J M, Van Loan C F. Signal processing computations using the generalized singular value decomposition// *Proc. SPIE*.

Vol. 495, *Real Time Signal Processing VII*, 1984:47-55

[4] Van Loan C F, Speiser J M. Computation of the CS Decomposition with Applications to Signal Processing// *Proc. SPIE*. Vol. 696, *Advanced Signal Processing Algorithms and Architectures*. 1986  
 [5] Van Loan C F. Generalizing the Singular Value Decomposition. *SIAM J. Numerical Analysis*, 1976, 13(1):76-83  
 [6] Paige C C, Saunders M A. Towards a Generalized Singular Value Decomposition. *SIAM J. Numerical Analysis*, 1981, 18(3):398-405  
 [7] Howland P, Park H. Generalizing Discriminant Analysis Using the Generalized Singular Value Decomposition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(8)  
 [8] Park C H, Park H. Nonlinear Discriminant Analysis Using Kernel Functions and the Generalized Singular Value Decomposition. *SIAM. J. Matrix Anal. & Appl.*, 2005, 27:87  
 [9] Boser B E, Guyon I, Vapnik V. A training algorithm for optimal margin classifiers// *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*. ACM Press, 1992:144-152  
 [10] 袁立,穆志纯,刘磊明. 基于核主元分析法和支撑向量机的人耳识别. *北京科技大学学报*[J], 2006(9)  
 [11] Mu Z C, Yuan L, Xu Z G. Shape and structural feature based ear recognition. *Advances in Biometric Person Authentication*. Guangzhou, 2004:66

(上接第250页)

真脚本,提供给仿真管理成员。由仿真管理成员将脚本文件转换为各仿真单元的配置信息,发送到其它联邦成员,实现系统的初始化、空间场景的生成和相关资源的加载。仿真过程中,极轨星成员和赤道星成员通过通信成员与地面系统进行数据交互,同时控制载荷工作状态和计算平台的相关状态数据。各成员协同完成卫星过地球辐射带的相关空间科学探测任务仿真和数据上下行仿真,并能根据需求改变仿真精度,实现卫星伸杆打开、太阳帆板展开、过阴影和数据上下行等平台 and 载荷工作情况的高精度仿真。可视化成员订购相关数据进行三维和二维显示,为论证人员提供广阔的空间环境、卫星运行状态和轨迹、地面系统状态等三维画面和三维图表。数据采集成员通过订购其它所有仿真成员的相关数据实时地收集仿真数据,实现数据的标准化存储,为分析评估和后续的任务分析提供数据支持。评估成员根据用户需要读取数据库中的仿真信息进行分析评估,为论证人员改进和完善任务设计提供参考。

系统主要仿真单元的交互界面如图7所示。

**结束语** 本文通过对空间科学任务仿真系统的开放式体系结构设计,建立了基于HLA/RTI的可扩展的仿真平台,并实现了双星科学任务的不同细节程度仿真,通过仿真对双星科学任务的可行性以及SSDRSS对科学任务论证的促进作用做出了正确评估。在此基础上对仿真系统进行少量的扩展和修改,就能够满足我们正在进行的火星探测任务仿真的需要。实验证明,该仿真系统能够满足空间科学与探测任务论证的需要,具有很好的实用价值和可扩展性,为今后的空间科学任务仿真系统开发提供了借鉴作用。

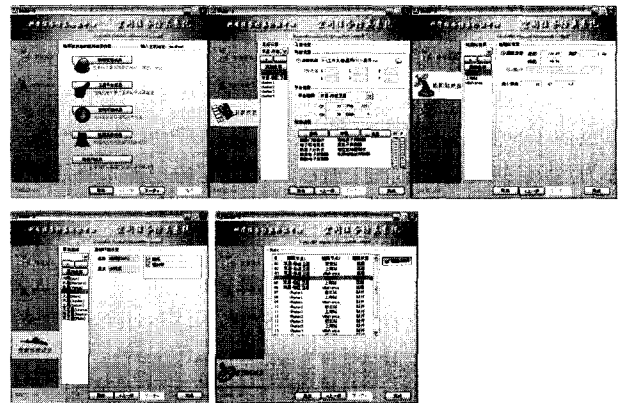


图7 主要仿真单元实现界面

### 参 考 文 献

[1] 周彦,戴剑伟,等. HLA 仿真程序设计[M]. 北京:电子工业出版社,2002  
 [2] 黄晓冬,何友,徐俊艳. 一种基于HLA的弹性软件框架及其应用[J]. *系统仿真学报*, 2005, 17(1):95-99  
 [3] 马贤颖,李学军,陈晓娟. 大区域虚拟战场环境中仿真平台的设计[J]. *系统仿真学报*, 2006, 18(1):76-84  
 [4] Argltello L, Mir6 J. Distributed Interactive Simulation for Space Projects [J]. *European Space Agency Bulletin (S0376-4265)*, 2000(102):125-130  
 [5] U. S. Department of Defense. High Level Architecture Object Model Template Specification Version 1.3[S]. 1998