

文章编号:1001-9081(2006)09-2250-05

基于加权 PCA 的声音指纹降维技术

胡永刚^{1,2}, 吴 翊¹, 卜 江¹

(1. 国防科学技术大学 数学与系统科学系, 湖南 长沙 410073;

2. 酒泉卫星发射中心, 甘肃 兰州 732750)

(xd7688@hotmail.com)

摘 要: 声音指纹技术现在已经广泛的应用到了歌曲搜索、乐曲识别、声音修复等各个领域,但其关键技术——音频降维技术仍存在分类效果不好、可靠性不高等问题。针对音频数据高维化存在较大随意性,提出了基于模式识别的音频数据高维化的最优方法。并在此基础上,提出了采用加权 PCA 方法作为声音指纹的降维技术,不仅分类效果大为明显,且由于方法还保持了线性方法的简单性,保证了大批量处理数据成为可能。

关键词: 加权主成分分析; 声音指纹; 线性降维

中图分类号: TP181 **文献标识码:** A

Dimensionality reduction in audio fingerprint based on weighted PCA

HU Yong-gang^{1,2}, WU Yi¹, BU Jiang¹

(1. Department of Mathematics and System Science,

National University of Defense Technology, Changsha Hunan 410073, China;

2. Jiuquan Satellite Launch Center of China, Lanzhou Gansu732750, China)

Abstract: Audio fingerprint technology has been widely used in the music searching, melody identification, and sound restoration. However, dimensionality reduction, the key to audio fingerprint technology, still cannot achieve satisfactory classification and reliability. Firstly, this paper introduced an optimal audio-dimensionality-segment method based on pattern recognition. Secondly, weighted PCA(Principal Component Analysis) was suggested as the kernel dimensionality reduction technology in audio fingerprint processing. This method not only enhances the classification of music data, but also keeps the merits of linear dimensionality reduction, simplicity and fast computation, which makes the heavy-data-processing become feasible.

Key words: weighted PCA(Principal Component Analysis); audio fingerprint; linear dimensionality reduction

0 引言

音频特征提取是音频分类、修复以及识别等工作所必需的步骤^[1,2]。要取得较好效果,必须先解决音频特征提取所面临的几个问题^[3]:首先,对原始数据必须进行有效的降维处理。目前普通数字音乐的采样频率一般都为 44.1kHz,要能有效的区分一首音乐我们至少采样 5s 以上的数据,则其数据量就为 $5 \times 441000 = 2205000$ 个数据点。因此即使我们进行欠采样处理,要对原数据进行有效的表示,其每个数据点的维数仍在几百到上千个,维数这么高的数据必须进行降维处理;其次,提取的特征应当对音频失真具有较大的鲁棒性。比如,音乐可能经过不同的压缩转换和其他非线性操作,使得数据较原数据有较大的非线性失真,此时经过处理的特征应当和原特征的欧式距离较为接近;第三,不同的音频之间的特征在某种度量下区分较为明显,否则所提取的特征就失去了本身的意义;最后,特征提取的运算过程应当快捷方便,在典型的 PC 机上运行时占用较少的 CPU 资源。

先前的研究方多集中在对某种特定任务^[4,5](比如音频

分类、分割等)而自行设计的特征提取方法,常见的有过零率,能量测度,谱元测度以及由这些参数派生出来的特征等。但这些自行设计的特征只能在特定任务下小范围内使用。

文献[6]在 2003 年以音频流为对象提出了基于 OPCA^[7](Oriented Principal Component Analysis)(有人也称为 LDA(Linear Discriminant Analysis)方法,但该方法在内涵上不完全等同 LDA 方法)降维方法的 DDA^[7](Distortion Discriminant Analysis)方法,该方法在一定程度上对流媒体的识别提出了有效的解决办法,取得了较好的成果。但不足的是,OPCA 算法虽然是线性的,但其分类效果并不理想,仍然存在结果不很稳定,密钥过长的问题。基于此,本文在 DDA 算法的基础上,提出了基于加权的 w-PCA 的音频降维技术。

1 音频数据的高维化

现在的数字信号方面图像的高维化技术^[8]日渐成熟,但音频信号的高维化仍没有较好的解决,主要存在的问题:声音的维数如何选择?对单声道数字音频而言,其内容就是一个一维的数组,从直观意义似乎怎么分割都可以,因此分割显得

收稿日期:2006-03-13; 修订日期:2006-05-23

作者简介:胡永刚(1976-),男,河南平顶山人,硕士研究生,主要研究方向:数据降维、模式识别、图像融合、变化检测; 吴翊(1948-),男,浙江绍兴人,教授,博士生导师,主要研究方向:数据融合、随机控制、实验系统分析与评估; 卜江(1983-),湖南衡阳人,硕士研究生,主要研究方向:图像融合、图像感兴趣区域提取的高维方法。

较为随意。然而试验中可以发现不恰当的维数选择,往往使得结果变得毫无意义。下面我们从模式识别的角度,寻求音频文件的最优分解。

对 N 个采样点的音频文件进行分割,记为 $P_k[C_k, 2^k]$ 。它将原文件等分为 C_k 块,每块的大小取为 2^k ,可获得 2^k 维空间中容量为 C_k 的数据集。显然分割过于稠密或过于稀疏都是不可取的,维数过高使获得的高维数据点过于稀少,由于维数灾难的原因使得降维过程没有意义;同样维数过于低,使得数据本征结构对数据的微小改变非常敏感,从而难于提取准确的本征结构。故可以想象存在一个最优分割 P^* ,使得在这一分割之下可以获得最优的识别效果。但就实际问题而言,人们经常是在准确性和计算简单性之间进行折中,从而获得次优的 P^* ,当然它也与选择的识别方法有关,这里我们考虑加权PCA方法。这里对于 P^* 的选择采用固定分割方式的方法,即通过令相邻两部分具有一定的重叠,使得 C_k 唯一确定,从而依据训练集合,通过从大到小选择不同的 k 便可获得最优分割 P^* 。

设由上述方法分割的原音频在分割 $P_k[C_k, 2^k]$ 下的 2^k 维数据集 $X(k)$ 。这里我们选择相交的分割,即选择块与块之间的间隔为 2^{k-1} ,那么此时有:

$$C_k = \left\lfloor \frac{M}{2^{k-1}} \right\rfloor - 1, \quad [z] \text{ 表示不超过 } z \text{ 的最大整数} \quad (1)$$

下面利用降维方法来对 $X(k)$ 进行降维,获得原音频的低维特征表达向量 $\alpha(k) \in R^{C_k}$ 。为简洁起见,此处选择 $d = 1$ 。

给定已识别音频集合 $X(|X| = N, \text{等分为 } T \text{ 类})$,将其分为两部分,训练集合 X^1 和检验集合 X^2 。通过使检验集合的识别率达到最大,来寻找数据的最优分割 P^* 。

(1) 类学习

学习每类音频特征表达向量的中心点,并将其作为该类音频的代表,用于识别过程之中。首先获得每首音频 X_i 在分割 P_k 下的高维转化数据集 $X_i(k), i = 1, 2, \dots, N$; 然后对 $X_i(k)$ 进行降维,获得 C_k 维的特征表达向量 $\alpha_i(k), i = 1, 2, \dots, N$ 。计算每类音频的中心点 $Center_i \in R^{C_k}, i = 1, 2, \dots, T$ 。若令 $A = \{\alpha_1, \alpha_2, \dots, \alpha_n\} \in R^{C_k \times n}, (n = |X^1| / T)$ 代表某一类音频数据特征表达向量集合,那么它的中心点 α_0 满足:

$$\alpha_0 = \arg \max_{\alpha} \sum_{i=1}^n |\alpha^T \alpha_i|^2 = \arg \max_{\alpha} \left\{ \alpha^T \left(\sum_{i=1}^n \alpha_i \alpha_i^T \right) \alpha \right\}$$

易见 α_0 为矩阵 $\sum_{i=1}^n \alpha_i \alpha_i^T \in R^{C_k \times C_k}$ 的最大特征向量。

(2) 最优分割 P^*

对 X^2 中的每一元素 x_j , 计算 $\alpha_j(k)$ 与 $Center_i (i = 1, 2, \dots, T)$ 间的相似度(特征表达向量 $\alpha_j(k)$ 与 $Center_i$ 间的相似度为 $\rho(\alpha_j(k), Center_i) = |\alpha_j^T(k) Center_i|$), 寻求与其最相似的点, 识别 x_j 属于此类。

计算识别误差:

$$\varepsilon_k = 1 - \frac{|X^2 \text{ 中准确归类的点数}|}{|X^2|} \quad (2)$$

若 $\varepsilon_k \leq \varepsilon$, 则 $P^* = P_k$ 。若对 $\forall k$, 皆有 $\varepsilon_k > \varepsilon$, 那么选择 $P^* = \arg \min_{P_k} \{\varepsilon_k\}$, ε 为事先给定的常数。

(3) 识别过程

给定一音频, 在最优分割 P^* 下, 首先计算其特征表达向量 α ; 然后计算 α 与 $Center_i (i = 1, 2, \dots, T)$ 间的相似度, 获得与其最相似的点, 识别属于此类。

而在实际操作中, 如果计算结果要求不十分严格精确, 为了简化寻求 k 的过程, 我们常用试验的方法, 在确定使用降维方法的基础上, 通过结果比较投影结果大致选定分割的方法。就本文数据, 我们选得的最佳维数为 360, 约 33ms。

2 传统音频降维技术

用于音频指纹的降维方法有 PCA 和 Oriented PCA 两种。下面我们分别进行介绍。

给定向量 $x_i \in \mathbb{R}^d (i = 1, \dots, m)$, 其中 x_i 为一个向量, 这里表示一个信号(下面把未失真的数据都称为信号); 且对每一个信号 x_i 都有 N 个失真的版本 $\hat{x}_i^k, k = 1, \dots, N$ 。另外定义差向量 $z_i^k = \hat{x}_i^k - x_i$ 为噪音向量。一般而言, 我们希望能够找到与所有的 z_i^k 垂直线性投影方向, 且沿此方向信号 x_i 的投影方差同时最大化。假定此投影方向为 $n_i (i = 1, \dots, M)$, 其中 M 为任意选定, 为简单起见, 我们取 $M = 1$ 。

对 PCA 而言, 我们可以构建特征提取向量 n , 使得最小化下式的重建均方误差:

$$\frac{1}{mN} \sum_{i,k} (x_i - \hat{x}_i^k)^2, \quad \hat{x}_i^k \equiv (\hat{x}_i^k \cdot n)n \quad (3)$$

上述问题的直接解法就是求出 $R_1 - R_2$ 最大特征值对应的特征向量, 其中 R_1, R_2 为 x_i, z_i 各自的相关矩阵。然而, 这个特征提取的方法存在一个很大的缺陷: 当信号和噪音的尺度发生变化时, 投影方向也会发生变化。

OPCA 的方向选择较好地解决了这个问题。OPCA 定义的方向 n 为最大化 Rayleigh 等式:

$$q_0 = \frac{n^T C_1 n}{n^T C_2 n} \quad (4)$$

其中 C_1 为信号 x_i 的协方差阵, C_2 为噪音的协方差阵。注意到噪音项已经是差值项, 消除了均值不同造成的偏差, 这里 Burges 对 C_2 采用相关矩阵, 而不是协方差阵。具体为:

$$C \equiv \frac{1}{m} \sum_i (x_i - E[x])(x_i - E[x])'$$

$$R \equiv \frac{1}{mN} \sum_{i,k} z_i^k (z_i^k)'$$

上式简化为:

$$q = \frac{n^T C n}{n^T R n} \quad (5)$$

分子表示信号投影的方差, 分母表示投影后的误差均方。上式对 n_i 求导, 令 $\nabla q = 0$, 问题就转化成广义特征值问题:

$$C n = q R n \quad (6)$$

从上面分析来看, PCA 和 OPCA 都是试图寻求一种空间投影, 使得原始信号 x_i 和变形后的信号 \hat{x}_i^k 投影后尽可能的靠近, 且彼此不同的信号之间尽可能的有所区分, 而这点也正是音频指纹的本质所在。而 w-PCA 技术恰恰在这方面优于二者。后面的试验结果很好的说明了这点。

3 基于加权的 PCA 降维技术

降维方法总的来讲分为线性和非线性的两类, 线性降维

方法包括 PCA、PP (Projection Pursuit)、LDA、MDS (Multidimensional Scaling)、ICA (Independent Component Analysis) LUP^[9] (Local Unchanged Projection) 等,非线性降维技术有 LLE (Local Linear Embedding)、Isomap 以及 Laplacian Eigenmap 等。尽管线性的降维方法较非线性有许多缺陷,尤其 LLE^[10] 方法和 Laplacian Eigenmap^[11] 方法在流形上的成功应用更显线性的先天不足,但在实际解决问题时,线性降维的众多优点使得我们还难以对之割舍:

1) 线性降维的低维化结果是可靠的,它反映了原数据的真正属性,相反,非线性方法改变了原数据的拓扑结构,使得数据从某种角度上更加难以辨认;

2) 低维投影坐标方向意义明显,它是原来坐标方向的线性组合。有时,对这种组合性质的分析可能得出令人感兴趣的特定域特征的解释;

3) 从计算角度讲,变换矩阵可以存在内存中,新的数据随时就可以进行像原数据同样的变换;

4) 一般而言,线性的计算复杂度是非常低的,这不仅反映在计算速度上,也反映在计算时所占用的空间上。

而主成分分析 (PCA) 方法,具有概念上的简单性,计算上的方便性,以及最优线性重构误差等优良的特性,从而使得 PCA 方法成为线性降维方法中最为常用的方法,在实际数据处理中也是应用最为广泛的降维方法之一。在信号处理领域中,它对应着众所周知的 Karhunen-Loeve 变换。而加权 PCA^[12] 更把这个方法的优点发挥到了极致。下面我们分析 w-PCA 的数学原理。

给定向量 $x_i \in \mathfrak{R}^d (i = 1, \dots, m)$, 其中 x_i 为一个向量,假定数据已经中心化,即:

$$\sum_{i=1}^n X_{i\alpha} = 0, \quad \alpha = 1, \dots, m$$

令:

$$dist_{ij} = \sqrt{\sum_{\alpha=1}^m (X_{i\alpha} - X_{j\alpha})^2}$$

表示 X_i 和 X_j 在原始空间的欧式距离,

$$dist_{ij}^p = \sqrt{\sum_{\alpha=1}^m (X_{i\alpha} - X_{j\alpha})^2}$$

表示 X_i 和 X_j 在低维空间内两个点之间的欧式距离。

由 PCA 的定义可知,PCA 是把彼此相关的变量投影到称之为主成分的不相关变量的空间中。其第一主成分变量对数据的影响最大,其他成分的影响迅速减少。PCA 通过仅仅利用前面几个主要成分的投影来达到数据维数的显著降低,同时最大可能的保持数据方差。也即 PCA 的最大特性就是保证方差不变。这里我们从另外一个角度揭示 PCA 的本质。我们首先给出以下结论:

定理 1 PCA 的 p 维投影方向就是保证下式最大化的投影方向:

$$\sum_{i < j} (dist_{ij}^p)^2 \tag{7}$$

在证明定理 1 之前我们先定义单位 Laplacian 矩阵,用 L^u 表示,其中:

$$L_{ij}^u = \delta_{ij} \cdot n - 1 \tag{8}$$

$$\delta_{ij} = \begin{cases} 0, & i \neq j \\ 1, & i = j \end{cases} \tag{9}$$

由图论知识可知,Laplacian 矩阵是描述数据量之间对应关系重要元素之一,它是个对称、半正定矩阵,每行元素和为零,它所对应的一个二次多项式恰好是所有各点之间欧式距离的平方和。

我们有下面的引理:

引理 1 $X^T L^u X = n^2 \cdot S \quad S = \frac{1}{n} X^T X$

证明 我们只考虑两个矩阵中的任一个元素:

$$\begin{aligned} (X^T L^u X)_{\alpha\beta} &= \sum_{i,j=1}^n L_{ij}^u X_{i\alpha} X_{j\beta} \\ &= \sum_{i,j=1}^n (n \cdot \delta_{ij} - 1) X_{i\alpha} X_{j\beta} \\ &= \sum_{i=1}^n n \cdot X_{i\alpha} X_{i\beta} - \sum_{i,j=1}^n X_{i\alpha} X_{j\beta} \\ &= n \cdot (X^T X)_{\alpha\beta} - \sum_{i=1}^n X_{i\alpha} \cdot \sum_{j=1}^n X_{j\beta} \\ &= n^2 S_{\alpha\beta} \end{aligned}$$

下面我们再证明上述定理:

证明 由于在 p 维投影空间内 X 投影为: Xv^1, \dots, Xv^p , 则有:

$$\begin{aligned} \sum_{i < j} (dist_{ij}^p)^2 &= \sum_{\alpha=1}^p (Xv^\alpha)^T L^u (Xv^\alpha) \\ &= \sum_{\alpha=1}^p (v^\alpha)^T (X)^T L^u X v^\alpha \end{aligned}$$

因此,上述式子的最大和可以转化为:

$$\max_{v^1, \dots, v^p} \sum_{\alpha=1}^p (v^\alpha)^T (X)^T L^u X v^\alpha, \quad (v^\alpha)^T v^\beta = \delta_{\alpha\beta} \text{ 且 } \alpha, \beta = 1, \dots, p$$

显然上式的解就是 $(X)^T L^u X$ 最大 p 项特征向量。

由上述结论给了我们一个启发:在保证 L 为 Laplacian 矩阵的前提下,更换矩阵中的某些元素的大小,则下式:

$$\arg \max \left[\sum_{i < j} d_{ij} (dist_{ij}^p)^2 \right] \tag{10}$$

的解仍为 $(X)^T L^d X$ 最大 p 项特征向量,结论是显然的。

式(10)实质上就表示各点距离平方的加权和。根据各量之间权值的大小来控制我们所想要的各元之间的制约关系。比如,令 $\{d_{ij}\}_{i,j=1}^n$ 为对称非负权值,用它来测度数据点之间的相似程度(当 $i = j$ 时,我们取 $d_{ij} = 0$)。由此,上述式子化为:

$$\sum_{i < j} d_{ij} (dist_{ij}^p)^2$$

的最大和,此时 L 为:

$$L_{ij}^d = \begin{cases} \sum_{j=1}^n d_{ij}, & i = j \\ -d_{ij}, & i \neq j \end{cases} \tag{11}$$

d_{ij} 的定义有很多种,如欧式距离的倒数等,主要根据两点的相似程度进行定义,两点越相似其值越大。对监督类模式识别,只要定义类内为 1,类间为 0 就可。事实上,我们还有如下结论,对如下形式:

$$\max_{v^1, \dots, v^p} \frac{\sum_{i < j} d_{ij} (dist_{ij}^p)^2}{\sum_{\alpha=1}^p (v^\alpha)^T X^T X v^\alpha}, \quad (v^\alpha)^T v^\beta = \delta_{\alpha\beta} \text{ 且 } \alpha, \beta = 1, \dots, p \tag{12}$$

其最大化问题就是 Rayleigh 等式的问题,结果是当 p 取 $(X^T L^d X, X^T X)$ 的最大 p 特征向量。

注意到 $v^T X^T X v$ 就是在 v 方向投影的方差,分母是沿各个方向投影的方差的总和,因此,当分子保证最大化对应权重距离和时,分母通过最小化方差防止投影结果四下散射。这使得上式非常适合标号数据,增大了类间方差减小了类内方差。我们也正是利用加权 PCA 的这点特性,进行声音指纹技术研究的。

4 试验分析

为了能够清楚的表现出加权 PCA 在音频分类方面的优势,我们仅取少量的样本以便在投影到二维平面上时能够很好的分辨出来。

(1) 音频分类试验

我们的试验数据取自 10 段 20s 长度的音乐片断,采样频率降低为 11 025Hz; 音频数据高维化时,每点维数取 360 个点,每个数据采样 40 个点,用 0~9 的标号表示出各个类所在的位置。Laplacian 矩阵中 d_{ij} 定义为:

$$d_{ij} = \begin{cases} 0, & x_i \text{ 和 } x_j \text{ 不在同一类内} \\ 1, & x_i \text{ 和 } x_j \text{ 在同一类内} \end{cases}$$

试验环境采用 Matlab R14,数据降维后二维投影结果如图 1。




图 1 10 组音频数据的分类效果

图 1 中所示的投影方向很好的区分了各个类间差异,使得各类间能够清晰的分离出来。

(2) 特征提取试验

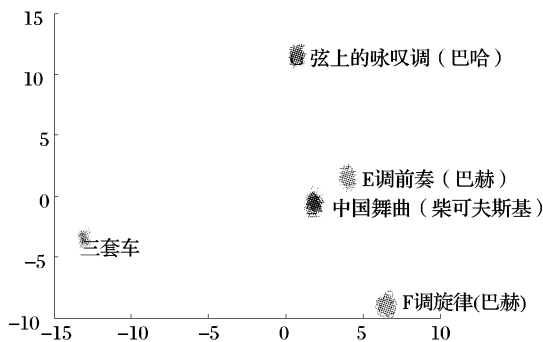


图 2 加权 PCA 方法得出二维效果

由于声音指纹的本质含义就是虽然数据经过变形、压缩,但反映其本质特征的特征数据应当没有发生变化。这也就是说,如果把我们将得到的特征提取的投影函数分别作用在原始数据和变形后的数据上,其投影结果应当聚在一起。图 2 为 10 组片断中提取的数据,参数选择如前,但 10 组数据中前

5 组为原始数据,后 5 组为对应数据进行 Compander 变形后的结果。变形参数为: -9dB 以上压缩比:3.75:1, -9dB 以下压缩比 1.1:1,在 -40dB 以下膨胀比为 2:1,补偿因子 0.3dB。从图中可以看出,经过 weighted PCA 处理之后,变形数据和原始数据很好的吻合起来。

说明:图 2 中每一类有两种颜色,一种是原始数据,另外一种是对应数据的变形。下同。

图 3、图 4 显示了用 OPCA 和 PCA 方法进行投影的二维结果,从图中可以看出,二维的投影不能把各首音乐和对应的音乐很好的对应起来。也就是说,要达到同样的分类效果,PCA 和 OPCA 必须提高分类的维数。这同时也说明如果采用加权 PCA 的降维方法确定音频的指纹,它将会降低所需密钥的维数。




图 3 采用 OPCA 的二维投影图




图 4 采用 PCA 得出的二维投影效果

(3) 维数变化时加权 PCA 投影试验




图 5 维数为 200 时分类结果

但是,我们同时也发现,加权 PCA 方法对数据的维数较为敏感,如果维数选择不当,结果将偏差较大。图 5 和图 6 为维数为 500 维的上述数据和 200 维时投影结果。

从图中可以明显看出,当数据取 200 维时已经发生混迭现象,当音频分割维数取 500 时结果已经在二维投影时无法

区分了。这是由于当维数过大时,对于数据点呈现多元高斯分布,数据点之间自然并无较大信息可以区分。因此,在运用加权 PCA 降维时维数的选取非常重要。




图6 维数为500维时分类的结果

5 结语

理论分析和试验结果表明,加权 PCA 降维技术在声音指纹提取中数据低维化方面较之传统方法有着显著的优越性。这不仅体现在该方法在分类效果的显著优势,而且该方法保持了 OPCA 和 PCA 所具有的线性降维方法计算方便快捷的特点,这为大批量的数据计算提供了有效的保障。但不足之处在于该方法对于音频数据维数的选取较为敏感,过大,过小都会导致结果分类结果在边缘发生混迭现象,严重的就失去了分类的效果。因此,今后研究的重点将在如何提高方法的稳健性上深入剖析该理论上的原因。

参考文献:

- [1] ZHANG T, KUO CCJ. Heirarchical classiciation of audio data for archiving and retrieving[A]. Proc. IEEE Int. Conf. Acoustics, Speech, and Signal Processing[C], 1999, 6: 3001 - 3004.
- [2] LU L, JIANG H, ZHANG H. A robust audio classification and segmentation method[R]. Microsoft Research, Redmond, WA, Tech. Rep., 2001.
- [3] Burges CJC, Platt JC, Jana S. Distortion discriminant analysis for audio fingerprinting[A]. IEEE Trans. Speech and Audio Processing [C], 2003, 11: 165 - 174.
- [4] FOOTE J. Content-based retrieval of music and audio[A]. Proc. SPIE[C], 1997. 138 - 147.
- [5] SEO JS, JIN M, LEE S, et al. Audio fingerprinting based on normalized spectral subband centroids[EB/OL]. http://mmp.kaist.ac.kr/~sunillee/papers/conf_ICASSP_2005_aufing.pdf, 2005.
- [6] DIAMANTARAS K, KUNG S. Principal Component Neural Networks[M]. New York: Wiley, 1996.
- [7] BURGES C, PLATT J, JANA S. Extracting noise robust features from audio data[A]. Proc. Int. Conf. Acoustics, Speech, Signal Processing[C], 2002. 1021 - 1024.
- [8] 谭璐. 高维数据集的结构[D]. 长沙: 国防科技大学, 2005.
- [9] 谭璐, 易东云, 吴翊, 等. 局部不变投影[J]. 自然科学进展, 2004, 14(3).
- [10] ROWEIS ST, SAUL LK. Nonlinear dimensionality reduction by locally, linear embedding[J]. Science, 2000, 290(12): 2323 - 2326.
- [11] BELKIN M, NIYOI P. Laplacian Eigenmaps for Dimensionality Reduction and Data Representation [J]. Neural Computation, 2003, 15(6).
- [12] KOREN Y, CARMEL L. Robust Linear Dimensionality Reduction [J]. IEEE Transactions On Visualization And Computer Graphics, 2004, 10(4).

(上接第 2243 页)

采购计划单与采购订单之间的关联关系可以通过与上述相同的方式建立。

2.3 关联关系查询

由图 6 和图 7 建立的关联关系可以由图 8 所示界面进行查询,即对关联日志表的查询。关联关系查询完成两个功能:

- 由上游业务对象查询与之关联的下游业务对象及关联信息,即实现关联的追溯;
- 由下游业务对象查询与之关联的上游业务对象及关联信息,即实现关联的回溯。

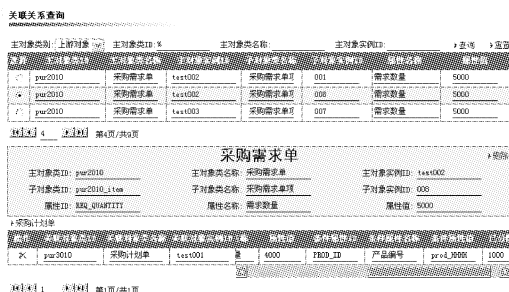


图8 关联关系查询

2.4 关联关系重构

前面讲述了由采购需求单生成采购计划单再生成采购订单的业务过程。当业务过程发生变化,如图 1(c)需要增加采购需求单→采购订单流程,即建立采购需求单与采购订单的关联,采购需求单、采购计划单和采购订单的处理逻辑和现有的关联都无需改变,只需增加复合操作“需求单生成订单”和“建立需求单与订单关联”来处理需求单与订单的关联关系。

这种方法既把原来已有的劳动成果继承下来,又实现了系统的快速重构,降低了重构的代价和复杂性。

3 结语

基于状态和关联日志的可追溯的业务对象关联模型的建立为关联两个业务对象提供了一种新的方式,利用关联日志保存关联的好处是显而易见的,这种关联方式克服了传统方式中破坏业务对象独立性、难以实现对象间追溯、重构复杂性高等缺点,不但能灵活地实现业务对象之间的多种关联关系、具有可追溯性,当企业需求发生变化时减小了软件重构的复杂性,降低了重构成本。

参考文献:

- [1] 李龙, 麦中凡, 曹广通. OODB 中对象关系的实现[J]. 小型微型计算机系统, 1996, 17(8): 8 - 15.
- [2] 万建成, 倪惠青. 对象关系的外连式实现方法[J]. 小型微型计算机系统, 2002, 23(7): 844 - 848.
- [3] 林守勋, 林宗楷, 郭玉钗. 联系的概念、实现及其应用[J]. 计算机研究与发展, 1998, 35(4): 333 - 337.
- [4] 顾彬, 董小国, 汪须忠. 面向表单的对象模型的研究[J]. 北京化工大学学报, 2005, 32(5): 95 - 97.
- [5] 柴跃廷, 张晓东, 李芳芸. 敏捷信息系统的研究[J]. 计算机集成制造系统—CIMS, 1999, 5(2): 6 - 10.
- [6] 王忠杰, 徐晓飞, 战德臣. 一种面向重构的业务过程模型[J]. 计算机集成制造系统, 2004, 10(11): 1349 - 1355.
- [7] 边世红, 薛劲松, 宁学艳. ERP 系统中持久对象动态性研究[J]. 计算机集成制造系统, 2003, 9(5): 378 - 383.
- [8] 王忠杰, 徐晓飞, 战德臣. 面向重构的企业应用系统业务模型[J]. 计算机应用, 2005, 25(8): 1861 - 1864.