

基于改进 T-S 模型的航空 发动机振动值监控方法

孙逢啸, 倪世宏, 谢川

(空军工程大学 航空航天工程学院, 西安 710038)

摘要: 针对 T-S 模型在规则库建立过程中存在的重复学习、效率低下等问题, 采用模糊关联规则挖掘的方法对 T-S 模型进行改进; 首先采用基于矩阵的模糊关联规则挖掘算法, 深入分析和利用频繁项集的性质, 减少数据库扫描次数以及挖掘过程中产生的中间结果, 提高规则挖掘效率; 其次, 从挖掘结果中选取模糊规则, 对其处理后建立 T-S 模型规则库; 最后, 将改进的 T-S 模型应用于航空发动机振动值监控中; 实验结果表明, 改进的 T-S 模型能够有效实现发动机振动监控。

关键词: 模糊关联规则; T-S 模糊模型; 规则库; 发动机振动值监控

Method of Aero Engine Quiver Monitoring Based on Improved T-S Model

Sun Fengxiao, Ni Shihong, Xie Chuan

(Aeronautics and Astronautics Engineering College, Air Force Engineering University, Xi'an 710038, China)

Abstract: Given defects of repetitive learning, inefficiency and so on during establishment of T-S model rule base, T-S model is improved based on method of association rules mining. Firstly, it is adopted that fuzzy association rules mining algorithm based on matrices, which analyze further and utilize frequent items properties. Thus, with database scans and intermediate results generated reduced, efficiency of mining rules is prompted. Secondly, association rules abstracted from results are altered for establishment of T-S model rule base. At last, the improved T-S model is applied to monitor aero engine quiver. Emulation experiments show the T-S fuzzy model succeeds in monitoring engine quiver.

Key words: fuzzy association rules; T-S fuzzy model; rule base; engine quiver monitoring

0 引言

航空发动机的振动信号携带着丰富的故障信息, 监控发动机振动值变化趋势对于及时发现发动机故障和开展视情维修, 具有重要实用价值。模型辨识是一种灵活、适用范围广泛的监控方法, 对于航空发动机而言, 只要得到准确的模型, 就可以据此进行状态监控和故障诊断。神经网络^[1-2]、支持向量机^[3-4]等是常见的模型辨识方法, 但以此建立的模型都是“黑匣子”模型, 建立的模型内部参数没有实际物理意义。

高木一关野 (T-S) 模糊模型^[5]是一种经典的模糊模型, 它是一种“灰匣子”模型, 有助于理解系统的内在机理。其中, 规则库是 T-S 模型的核心部分, 本文基于模糊关联规则挖掘建立 T-S 模型的规则库, 实现对 T-S 模糊建模的改进。为了进行模糊关联规则挖掘, 需要将系统的输入输出空间进行模糊划分, 在此基础上, 将样本集转化为模糊样本集; 采用基于矩阵的模糊关联规则挖掘算法对模糊样本集进行规则挖掘, 根据得到的规则建立 T-S 模糊模型的规则库。将改进的 T-

S 模型应用于航空发动机振动值监控, 实验结果表明, 基于模糊关联规则的 T-S 模糊模型具有较好的学习能力和泛化性能, 能够有效的实现对航空发动机振动值的监控。

1 样本集的模糊划分

在进行模糊关联规则挖掘和 T-S 模糊建模之前, 需要对系统的输入输出空间进行模糊划分, 并根据划分结果确定模糊集。本文采用文献 [6] 中的 Sub_FCM 聚类算法获取样本集合理的划分结果。模糊集的隶属度函数采用高斯函数 $y =$

$\exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right]$, μ 和 σ 的计算公式^[7]如下:

$$\begin{cases} \mu = v \\ \sigma = \sqrt{-\frac{\sum_{i=1}^n (x_i - \mu)^4}{2 \sum_{i=1}^n (x_i - \mu)^2 \ln u_i}} \end{cases} \quad (1)$$

式中, x_1, x_2, \dots, x_n 为 n 个样本点, u_1, u_2, \dots, u_n 为样本点隶属于某一聚类中心 v 的隶属度。

2 基于矩阵的模糊关联规则挖掘算法

进行高效模糊关联规则挖掘的关键在于快速找出所有的频繁项集, 对此学者进行了很多研究^[8-9]。本文采用基于矩阵的模糊关联规则挖掘算法 (Fuzzy Data Mining Algorithm Based on Matrix, FDMAM), 将模糊数据库转化为模糊事务矩阵, 支持度的计算可以通过对矩阵的操作进行, 只需要扫描一次数据库, 同时运用频繁项集的性质减少生成的模糊候选项集的数目, 以较高的效率实现模糊关联规则的挖掘。

收稿日期: 2014-01-18; 修回日期: 2014-02-28。

基金项目: 陕西省自然科学基金青年项目 (2012JQ1019)。

作者简介: 孙逢啸 (1990-), 河南驻马店人, 硕士, 主要从事飞行数据智能处理、数据挖掘方向的研究。

倪世宏 (1963-), 江苏南京人, 博士, 博导, 主要从事智能故障诊断、飞行数据智能处理等方向的研究。

谢川 (1974-), 四川自贡人, 副教授, 博士, 主要从事智能故障诊断、飞行数据智能处理等方向的研究。

2.1 相关定义与性质

通过 S₋FCM 算法将样本集进行模糊划分后, 需要将样本集转化为模糊数据库才能进行模糊关联规则挖掘。模糊数据库的属性集为原数据库所有属性的不同模糊等级的集合, 模糊数据库的记录即为原数据库中相应记录的所有属性值的隶属度值。设 $I = \{i_1, i_2, \dots, i_m\}$ 是数据库 D 的属性集, D_F 为数据库 D 转化得到的模糊数据库, $I_F = \{i_1^1, i_1^2, \dots, i_1^n, i_2^1, i_2^2, \dots, i_2^n, \dots, i_m^1, i_m^2, \dots, i_m^n\}$ 为 D_F 的属性集。

定义 1: 定义矩阵 $\mathbf{FA} = (a)_{i \times j}$ 为模糊事务矩阵, 其中 a_{ij} 为 D_F 第 i 个记录中的属性值, 在 I_F 中第 j 个模糊属性上的隶属度。

由定义 1 可知, \mathbf{FA} 的每一列表示不同记录中的属性值隶属于同一模糊集的隶属度, 每一行表示同一条记录中不同的属性值隶属于相应模糊集的隶属度。设模糊属性集 $X = \{x_1, x_2, \dots, x_p\}$, X 的模糊支持度计算公式如下:

$$FSup = \frac{\sum_{i=1}^n \prod_{j=1}^p a_{ij}}{n} \quad (2)$$

其中: l_j 为属性 x_j 在模糊事务矩阵 \mathbf{FA} 中对应的列, a_{ij} 为第 i 个记录中的属性值在模糊属性 x_j 上的隶属度, n 为数据库记录的总数。

性质 1: 对于两个模糊频繁 k -项集 ($k \geq 2$), 若其中 $k-1$ 项相同, 剩下两项组成的 2-项集为模糊频繁项集, 那么它们两个连接形成的 $k+1$ -项集的所有子集都是模糊频繁项。

证明: 设两个模糊频繁项集为:

$$\begin{aligned} x &= i_x(1)i_x(2)\dots i_x(k-1)i_x(k) \\ x' &= i_{x'}(1)i_{x'}(2)\dots i_{x'}(k-1)i_{x'}(k) \end{aligned} \quad (3)$$

其中: $k \geq 2$, $i_x(p)$ 和 $i_{x'}(p)$ ($p=1, 2, \dots, k$) 分别为项集 x 和 x' 中的第 p 项。不失一般性, 假设 $i_x(1) = i_{x'}(1)$, $i_x(2) = i_{x'}(2), \dots, i_x(k-1) = i_{x'}(k-1)$, $i_x(k) \neq i_{x'}(k)$, 则 x 和 x' 连接形成的 $k+1$ -项集为 $x'' = i_x(1)i_x(2)\dots i_x(k-1)i_x(k)i_{x'}(k)$, 则 x'' 所有子集由 x 的所有子集和 $i_x(k)i_{x'}(k)$ 构成。又由 x 为模糊频繁项集知 $i_x(1)i_x(2)\dots i_x(k-1)i_x(k)$ 所有子集都是频繁的, 由题设知 $i_x(k)i_{x'}(k)$ 为模糊频繁项集, 即 x'' 所有子集为频繁项。证毕。

性质 2: 模糊数据库 D_F 的频繁 k -项集 ($k \geq 2$) 中的模糊属性按字典序进行排列后分组, 同一组中的模糊项集前 $k-1$ 个属性相同, 则任一所有子集都是模糊频繁项集的 $k+1$ -项集都可由同一组中的两个模糊频繁 k -项集相并生成, 且这两个模糊频繁 k -项集是唯一的。

证明: 设任一子集都为频繁项集的 $k+1$ -项集为:

$$y = i_x(1)i_x(2)\dots i_x(k-1)i_x(k)i_x(k+1) \quad (k \geq 2) \quad (4)$$

可知, y 的前 $k-1$ 项相同的子集有且只有两个, 分别为:

$$\begin{aligned} x &= i_x(1)i_x(2)\dots i_x(k-1)i_x(k) \\ x' &= i_x(1)i_x(2)\dots i_x(k-1)i_x(k+1) \end{aligned} \quad (5)$$

又因 y 的任一子集都是频繁的, 则 x 和 x' 的为频繁项集, 且在同一块内, 即对于任意 y 都可以由同一类中的 x 和 x' 相并生成, 且 x 和 x' 是唯一的。证毕。

2.2 算法描述

FDMAM 算法通过将数据库转化为模糊事务矩阵及矩阵上的操作, 减少数据库的扫描次数, 同时减少生成模糊候选项

集的数目, 从而提高了模糊关联规则的挖掘效率。所有模糊项集的元素都按照字典顺序排列。

算法具体步骤如下。

输入: 数据库 D , 最小支持度 \minFSup , 最小置信度 \minFConf 。

输出: 模糊关联规则 R 。

FDMAM 算法的具体步骤如下:

(1) 将数据库 D 转化为模糊数据库 D_F 。设 D 属性集为 $I = \{i_1, i_2, \dots, i_m\}$ 、 D_F 属性集为 $I_F = \{i_1^1, i_1^2, \dots, i_1^n, i_2^1, i_2^2, \dots, i_2^n, \dots, i_m^1, i_m^2, \dots, i_m^n\}$, 其中 $\{i_j^1, i_j^2, \dots, i_j^n\}$ 为在属性 i_j 上划分的模糊等级。将 D_F 转化为模糊事务矩阵 \mathbf{FA} ;

(2) 通过式 (2) 计算每个模糊属性的支持度, 大于最小支持度的所有属性组成模糊频繁 1-项集的集合 L_1 。

(3) 组合 L_1 内的元素, 在数据库 D 中是同一属性不同模糊集的模糊属性不组合, 生成候选 2-项集的集合 C_2 。按照式 (2) 计算所有候选 2-项集的支持度, 所有支持度不小于最小支持度的 2-项集组成模糊频繁 2-项集的集合 L_2 , 所有支持度大于最小支持度的 2-项集组成模糊非频繁 2-项集的集合 NL_2 。

(4) 已知 L_k 为模糊频繁 k -项集的集合 ($k \geq 2$), 将 L_k 分组, 每一组前 $k-1$ 个元素相同。将 L_k 每一组内的元素两两组合, 生成候选 $k+1$ -项集 C_{k+1} 。对于同一组内的两个模糊频繁 k -项集其中若满足以下条件中的任一个便不能组合:

① 若两个模糊频繁 k -项集的最后项, 分别是数据库 D 中是同一属性不同模糊等级;

② 若取两个模糊频繁 k -项集的最后项构成的 2-项集, 属于模糊非频繁 2-项集的集合 NL_2 。

(5) 按照式 (2) 计算 C_{k+1} 中项集的支持度, 所有支持度不小于最小支持度的 $k+1$ -项集组成模糊频繁 2-项集的集合 L_{k+1} 。

(6) 重复执行步骤 (4)、(5), 直至得到所有的频繁项集;

(7) 由得到的频繁项集挖掘置信度不小于 \minFConf 的模糊关联规则。

由性质 1 可知, 步骤 (4) 中条件 ② 可以确保生成的每一个模糊候选项集项集的所有子集都是频繁的, 由此减少了生成候选项集的个数。同时, 由性质 2 可知, 步骤 (4) 中在 L_k 每一组内部进行两两组合生成候选 $k+1$ -项集, 这样生成的 C_{k+1} 包含所有每个子集都是模糊频繁项集的候选 $k+1$ -项集。

3 基于模糊关联规则的 T-S 模糊模型的建立

基于模糊关联规则的 T-S 模糊模型的建立具体步骤如下:

(1) 选取样本并对样本集进行模糊划分, 求出样本输入变量的各个模糊集的隶属度函数;

(2) 按照 2.2 节步骤进行模糊关联规则挖掘, 找出频繁出现的关联模式。选择合适的关联规则, 将规则的后件转变为输入变量的一阶线性表达式, 由此建立 T-S 模型的规则库。得到的规则形式为:

$$R_j: \text{If } x_1 \text{ is } A_1^{f_1} \text{ and } x_2 \text{ is } A_2^{f_2} \text{ and } \dots \text{ and } x_n \text{ is } A_n^{f_n} \text{ then } y_j = p_{j0} + p_{j1}x_1 + \dots + p_{jm}x_n \quad (j = 1, 2, \dots, m) \quad (6)$$

其中: (x_1, x_2, \dots, x_n) 是输入变量; y_j 是输出变量; $A_1^{f_1}, A_2^{f_2}, \dots, A_n^{f_n}$ 是规则 R_j 中定义在输入变量上的模糊集合; $p_j \in$

$\{1, 2, \dots, m_1\}, p_2 \in \{1, 2, \dots, m_2\}, \dots, p_n \in \{1, 2, \dots, m_n\}$, m_1, m_2, \dots, m_n 为输入变量各个分量上的模糊类别个数; $p_{j0}, p_{j1}, \dots, p_{jn}$ 为常数; n 为输入变量维数; m 为规则数。

(3) 根据得到的规则库, 建立 T-S 模型, 模型的内部参数分为规则前件各属性隶属度函数的参数和规则后件线性表达式的系数。规则后件系数设为 0, 步骤 (1) 中所求隶属度函数即为规则前件隶属度函数。按照文献 [10] 中的梯度优化方法调节规则模型内部参数, 构建相应的模糊神经网络, 并利用样本进行学习, 直至模糊模型的精度达到要求。

4 实验仿真

4.1 FDMAM 算法实验

实验数据为 UCI 数据集 glass 中的第 2 类——build wind non—float 数据, 数据共有 9 个连续属性, 由于挖掘模糊频繁项集在关联规则挖掘中占有大部分时间, 是衡量模糊关联规则挖掘算法的重要标准, 为了检验 FDMAM 算法的性能, 利用模糊 C—平均值算法将每个属性划分为 3 个模糊等级 (不考虑划分结果是否符合实际情况), 以挖掘模糊频繁项集的时间作为衡量算法效率的标准, 与应用最广泛的模糊关联规则挖掘算法之一——FDMA 算法^[11]进行对比。试验环境为 Inter (R) 3.30GHz CPU, 1.97GB 内存, 操作系统为 WindowsXP, 采用 Matlab7.8 编写程序。两者在不同的 minFSup 限制下, 挖掘得到的频繁项集完全相同, 这验证了 FDMAM 算法是正确的。由于频繁项集数量较多, 这里不再列出。

表 1 两种算法在 minFSup=0.2 时生成的候选项集数目

候选 k —项集数目	FDMAM	FDMA
2	105	105
3	124	472
4	128	910
5	79	894
6	17	453

由表 1 可以看出, FDMA 算法在生成模糊频繁项集的过程中, 生成了远多于 FDMAM 算法的模糊候选项集, 这些数目巨大的候选项集也是导致 FDMA 算法性能较低的一个重要因素, 而 FDMAM 算法有效地减少了模糊候选项集的数目。图 1 为两种算法的性能对比。




图 1 最小模糊支持度变化时两种算法性能比较

由图 1 可以看出, 当最小模糊支持度较大时, 两种算法差别不大。随着最小模糊支持度的较小, FDMA 算法耗费时间

迅速增加, 而 FDMAM 算法时间增加得较为缓慢, 当最小模糊支持度为 0.05 时, FDMA 算法耗时约 30 s, 而 FDMAM 算法耗时不到 1 s, 由此可以验证, FDMAM 算法的效率是远高于 FDMA 算法的。

4.2 基于模糊关联规则挖掘的发动机振动值监控

4.2.1 样本提取

某型飞机发动机在起飞、着陆阶段的振动模型可用以下非线性关系式表示:

$$Vib = f(N_1, N_2, BHA, HAPIC, PC) \quad (7)$$

式中, f 为未知的非线性函数关系; Vib 为发动机的振动值; N_2 和 N_1 分别为发动机的高低压转子转速; $HAPIC$ 和 BHA 分别为高低压压气机进口导流叶片转角; PC 为发动机喷口指示值。发动机振动监控的主要问题就是通过模型辨识的方法得到式 (7) 中的 f , 采用改进的 T-S 模型对 f 进行辨识, 得到发动机起飞、着陆阶段的“灰匣子”模型。因起飞、着陆阶段的振动监控模型在形式上完全一样, 为节省篇幅, 只讨论起飞阶段发动机振动监控模型的建立。

提取某型飞机起飞阶段加力稳态时的数据的数据作为研究对象, 由 (7) 式知提取的参数有: 振动值 Vib , 高低压转子转速 N_2 和 N_1 , 高低压压气机进口导流叶片角度 $HAPIC$ 和 BHA , 喷口指示值 PC , 得到飞机起飞阶段加力稳态样本 115 组。

4.2.2 基于模糊关联规则的发动机振动值监控实验

提取起飞样本集的前 78 组作为建立相应 T-S 模型需要的训练样本。对飞机起飞阶段进行发动机振动值建模。首先利用 S_FCM 算法对输入输出空间进行模糊划分, 表 2 为得到的聚类中心, 将输入变量的隶属度函数定位高斯函数, 表中括号内的值为按照 (1) 式估计得到的对应于不同模糊等级的隶属度函数的 σ 值, 隶属度函数的 μ 值即为相应的聚类中心。

表 2 输入输出空间模糊划分得到的聚类中心

变量	起飞阶段
N_1	93.25(1.46); 95.48(1.00)
N_2	95.57(0.95); 97.28(0.72)
BHA	103.96(5.65); 95.41(2.83)
$HAPIC$	109.41(0.20); 110.08(0.41)
PC	80.40(7.96); 73.55(5.12); 61.85(5.36)
Vib	18.87; 19.93; 17.86; 21.16; 22.65

将样本数据库转化为模糊数据库, 起飞阶段模糊数据库共有 16 个模糊属性。对其进行模糊关联规则挖掘, 根据 (4) 式, 发动机振动值是 $N_1, N_2, BHA, HAPIC, PC$ 等 5 个变量的非线性函数, 因此选取前件涉及到这五个变量的规则, 建立相应的模糊规则库和 T-S 模糊系统, 并训练模糊系统使其达到一定精度, 得到振动值的模糊模型。

设真实记录的振动值为 Vib_{ij} , 模糊模型输出的振动值为 \bar{Vib}_{ij} , i 为架次序号, j 为每个架次内的样本点次序。对于第 i 个架次, 模型输出与实测数据之间的绝对误差为:

$$|AB|_i = \sum_{j=1}^n |Vib_{ij} - \bar{Vib}_{ij}| \quad (8)$$

式中, n 为第 i 个架次内部的样本点数量。设 $E|A|$ 表示绝对误差的均值, $D|A|$ 表示绝对误差的方差。为了说明模型的有

效性, 进行以下实验。选取起飞阶段后 37 组作为模型测试样本集。起飞阶段测试样本集中前 27 组作为无故障检验样本。

(1) 考察模糊模型输出与实测数据之间的绝对误差, 以及模糊模型用于振动值监控的效果。挖掘起飞阶段模糊关联规则过程中令 $\min FSup=0.001$ 、 $\min FConf=0.5$, 训练模糊神经网络的步数为 500 步。由此得到的模糊模型的拟合绝对误差如表 3 所示。

表 3 起飞阶段模糊模型的拟合绝对误差统计

误差统计量	起飞阶段	
	训练样本	无故障检验样本
$E A $	0.853 3	1.384 8
$D A $	0.458 0	0.875 5

振动值的测量范围在 0~110 之间, 由表 3 可知模糊模型输出误差小于 1%, 模型精度满足工程要求。模糊模型拟合起飞阶段的振动值误差如图 2 所示。




图 2 起飞阶段模糊模型拟合误差

图 2 中前 78 个架次训练样本, 后 37 个架次为测试样本, 其中第 79~105 个架次为无故障检测样本; 由图 2 可以测试样本中有的架次拟合绝对误差较大, 这是由于建立的模糊模型反映了发动机参数 $N_1, N_2, BHA, HAPIC, PC$ 之间的对应关系, 当发动机正常工作时, 模型输出与飞参记录的数据误差较小; 当发动机振动异常时, 模糊系统描述的参数之间的协调关系找到破坏, 因而模型输出会与飞参实际记录值有较大误差。据此, 可以通过监控误差的变化, 实现发动机振动状态的监控。

利用“峰度、偏度法”检验可确定误差数据近似服从 $N(\mu, \sigma^2)$ 分布, 在置信概率为 99.87% 时, 把单侧置信区间的误差上限 $\mu+3\sigma$ 作为误差监控门限, 无故障检验样本的误差统计及由此确定的误差阈值如表 4 所示。

表 4 无故障检验样本误差统计及监控的误差门限

	μ	σ	$\mu+3\sigma$
起飞阶段	1.3848	0.8755	4.0113

根据监控门限, 05# 右起飞阶段最后一个架次误差超限。事实上, 起飞阶段的最后一个架次飞机右发空中停车, 这说明模型用于振动值监控是有效的。

(2) 支持向量机 (Support Vector Machine, SVM) 是一种经典的建模方法^[12], 在发动机振动值监控方面取得较好的效果。用 SVM 与 T-S 模糊模型对发动机振动值进行建模,

使两者对于训练样本的拟合绝对误差均值相等, 比较它们对于测试样本的拟合精度, 从而实现对他们的学习能力的对比, 两者对发动机进行建模时的参数设置及训练样本拟合误差均值如表 5~6 所示。

表 5 支持向量机模型内部参数及训练样本误差统计

	起飞阶段
核函数	高斯函数
惩罚系数 C	1
核宽度 σ	0.125
$E A $	0.860 81
$D A $	0.621 04

表 6 T-S 模糊模型内部参数及训练样本误差统计

	起飞阶段
$\min FSup$	0.001
$\min FConf$	0.5
训练步数	320
$E A $	0.860 82
$D A $	0.464 19

由表 5~6 中的误差统计可以看出, 得到的 SVM 模型和 T-S 模型对于训练样本的拟合绝对误差均值相差不足 0.1%, 而 T-S 模型的绝对误差方差小于 SVM, 这说明得到的 T-S 模型相对于 SVM 模型更充分地学习了训练样本集内的信息。两者对于测试样本和无故障检测样本的拟合结果如图 3 和表 7 所示。




图 3 起飞阶段 SVM 模型与 T-S 模型测试样本绝对误差

表 7 SVM 模型与 T-S 模型无故障检验样本绝对误差统计

无故障检验样本拟合误差统计	起飞阶段	
	SVM 模型	T-S 模型
$E A $	2.285 41	1.366 37
$D A $	1.267 43	0.818 52

由表 7 可以看出, T-S 模型对于无故障测试样本的拟合精度相对于 SVM 模型较高, 说明建立的 T-S 模型的泛化能力高于 SVM 模型。通过该实验可以看出, 通过模糊关联规则挖掘建立的适当的 T-S 模型有较好的学习能力和泛化性能。

5 结论

T-S 模型规则库的建立是 T-S 模糊建模的关键部分。

(下转第 1460 页)

护等功能的实现方法。

3.4.1 数据回放

数据回放是将指定时间段内、指定通道的遥测数据从数据库中查询出来并显示在用户界面上。Labview 中常用的方法是将所有查询出来的记录集里的数一次性转化并显示到 Labview 主界面的表格上。使用这种方法，如果查询的数据量不大，那么没有问题，但是，本系统遥测通道较多，每秒钟记录一次数据，通常一次需要回放几天的数据，那么需要查询的数据量就会很大，可能要查询几十万条记录，在这种情况下，如果采用上述方法，那么在获取查询数据并将其转化成适当格式显示时，需要耗费很大的内存，如果经常操作，会影响系统正常运行。本文设计了一种基于 Labview 的分段查询和显示方法，如图 4 所示，采用 SQL 指令查询，查询集获取、动态数据转换和显示采用分段法。每次只获取并显示数据表能直接显示在界面下的行数的数据，图 4 循环中的部分就是分段获取和显示的程序。通过拖动数据回放表格边上的滚动条，改变显示的数据和值，实现分页显示。通过这种方法，每次需要转化和显示的数据一次最多只有 30 行左右，占用内存很小。




图 4 数据回放程序框图

3.4.2 数据维护

数据维护包括将数据库表中的数据导出，导入等功能，以对数据库中的数据进行备份等管理。SQL 中有很多种方法可以将大批量数据导出，但是在 LABVIEW 中，目前尚无现有的方法可以实现将表中的大批量数据快速导出和导入。本文通过在 labview 中使用 BCP 成功实现将 SQL Server 中的表数据

导出为 txt 格式和将 txt 格式数据导入。BCP 导出数据所用的 SQL 指令为：Master. xp_cmdshell 'BCP 数据库名.dbo. 表名 out 导出路径\文件名.txt -c'。

数据导入的方法和数据导出方法类似，只是采用的 SQL 指令不同。

4 实验结果


将该系统进行测试，经 2 个月的不间断测试表明：系统的采样和处理周期为 0.7 s 左右，模拟信号采样通道的采样精度优于 0.1%，遥控信号的脉宽误差小于 2 ms，锂离子电池单体电压的偏差小于 50 mV，能有效的模拟卫星电源的各种在轨工作状态，很好的满足卫星电源的地面测试要求。

5 结束语

本文基于 Labview 设计并开发了一套针对卫星电源分系统的性能参数进行测试的系统，该系统能完成对太阳阵模拟器和电子负载的在线编程，实现卫星电源在轨状态的模拟，对遥测信号的采集和遥控信号的发送，对锂电池组的充电均衡控制、对遥测数据的回放和维护。该系统已用于测试了 3 种型号卫星电源分系统，运行结果表明，该系统监测数据准确，功能完善，运行高效可靠。

参考文献：

- [1] 王超, 张东来, 李勇, 等. 航天大功率 PCU 测试技术研究 [J]. 测控技术, 2012, 31 (11): 135-139.
- [2] 闰蕾, 王宇. 卫星电源测试评估系统的初步研究 [J]. 中国科学院研究生学报, 2005, 22 (1): 100-105.
- [3] 王梦玲, 王思明. 基于 PCI-1713 和 LabVIEW 的高速数据采集系统设计 [J]. 微计算机信息, 2006, 22 (7): 120-122.
- [4] 蒋薇, 张晓波, 赖青贵. 基于 LabVIEW 的仪器通信技术研究 [J]. 计算机测量与控制, 2013, 21 (4): 1030-1032.
- [5] 全钢, 常广晖, 胡春枝. Labview 访问 SQL 2000 数据库 [J]. 微计算机信息, 2011, 27 (8): 17-18.



(上接第 1449 页)

针对目前基于专家经验和样本建立规则库的不足，采用模糊关联规则的方法建立 T-S 模型的规则库。同时，为了快速挖掘关联规则，采用了基于矩阵的模糊关联规则挖掘算法。将改进的 T-S 模型用于监控航空发动机振动值监控，建立了航空发动机振动值监控的“灰匣子”模型，实验结果表明，得到的模型具有较好的学习能力和泛化能力。

参考文献：

- [1] 蔡国强, 邢宗义, 潘丽莎, 等. 采用遗传神经网络的轮轨力建模方法 [J]. 哈尔滨工业大学学报, 2012, 44 (7): 114-119.
- [2] 刘瑞叶, 黄磊. 基于动态神经网络的风电场输出功率预测 [J]. 电力系统自动化, 2012, 36 (11): 19-22.
- [3] 张军, 单永海, 曹殿广, 等. 基于最小二乘支持向量机的机舱加速寿命建模 [J]. 兵工学报, 2012, 33 (1): 63-98.
- [4] 李建宏, 姜同敏, 何玉珠, 等. 基于 NMF 的 SVM 故障诊断方法 [J]. 北京航空航天大学学报, 2012, 38 (12): 1639-1643.
- [5] Takagi T, Sugeno M. Fuzzy identification of systems and its appli-

- cation to modeling and control [J]. IEEE Transactions on Systems, Man and Cybernetics, 1985, 15 (1): 116-132.
- [6] 赵晓华, 谈玲珑, 胡敦利. 基于 Sub_FCM 聚类算法的交通流量路段自动划分方法 [J]. 北京工业大学学报, 2011, 37 (8): 1169-1174.
- [7] 陆建江, 张亚非, 宋自林. 关联规则的研究与应用 [M]. 北京: 科学出版社, 2008.
- [8] 崔建, 李强, 吴暇. 某机载雷达数据库关联规则挖掘算法研究 [J]. 计算机工程, 2011, 37 (18): 16-18.
- [9] 刘青宝, 王文熙, 王万军. 基于线性链表的模糊关联规则挖掘 [J]. 计算机科学, 2012, 39 (3): 135-138.
- [10] 田雨波. 混合神经网络技术 [M]. 北京: 科学出版社, 2009.
- [11] Hong T P, Kuo C S, Chi S C. Trade-off between time complexity and number of rules for fuzzy mining from quantitative data [J]. International Journal of Uncertainty Fuzziness and Knowledge-Based Systems, 2001, 9 (5): 587-604.
- [12] 李应红, 尉询凯, 刘建勋. 支持向量机的工程应用 [M]. 北京: 兵器工业出版社, 2004.