

## 数据驱动的复杂系统非预期故障诊断通用过程模型\*

陈彧赞<sup>1</sup>, 侯博文<sup>1</sup>, 何章鸣<sup>1,2</sup>, 王炯琦<sup>1,2</sup>

(1. 国防科技大学文理学院, 湖南长沙 410073; 2. 北京控制工程研究所, 北京 100080)

**摘要:**提高对复杂系统非预期故障诊断能力是故障诊断领域的难点。结合非预期故障诊断内涵及基本原理,构建了一种用于复杂系统非预期故障诊断的通用过程模型。该模型采用四层递进结构,包括四个主要模型,即预期(已知)故障检测模型、预期(已知)故障识别模型、非预期(未知)故障检测模型和非预期(未知)故障识别模型。分析了各模型所包含的关键问题及其相应的实现算法,包括检测统计量的构建及评估、故障特征方向提取、故障识别器设计及故障贡献率计算。该通用过程模型规范了复杂系统非预期故障的诊断流程,明确了数据驱动的实现原理。以卫星姿态控制系统为例,验证了非预期故障诊断通用过程模型的有效性。

**关键词:**非预期故障诊断;通用过程模型;数据驱动;检测统计量;偏离度;贡献率

**中图分类号:**TP206;N945.12 **文献标志码:**A **文章编号:**1001-2486(2017)06-126-08

## General process model for unanticipated fault diagnosis of complex system based on data driven

CHEN Yuyun<sup>1</sup>, HOU Bowen<sup>1</sup>, HE Zhangming<sup>1,2</sup>, WANG Jiongqi<sup>1,2</sup>

(1. College of Liberal Arts and Sciences, National University of Defense Technology, Changsha 410073, China;

2. Beijing Institute of Control Engineering, Beijing 100080, China)

**Abstract:** The unanticipated fault diagnosis for complex system is a difficult problem. A general process model was proposed. The model adopted a four-layer structure and included four models, i. e. an anticipated fault detection model, an anticipated fault identification model, an unanticipated fault detection model and an unanticipated fault identification model. Several key problems and the corresponding algorithms in each layer were analyzed, including the establishment of the fault detection statistic, the extraction of the fault character, the design of the fault isolation criterion and the construction of the fault contribution rate. The general process model regularized the diagnosis process of unanticipated fault for complex system and defined the data-driven fault diagnosis framework. The effectiveness of the proposed general process model was validated by a satellite control system.

**Key words:** unanticipated fault diagnosis; general process model; data-driven; detection statistic; deviation degree; contribution rate

从对故障认识和处理对策角度而言,故障可分为:预期故障和非预期故障<sup>[1-2]</sup>。一个完备故障库应该包括所有预期(已知)故障和非预期(未知)故障的集合。但是系统(如航天器系统、机器人系统及大型工业系统等复杂系统)复杂、全物理故障仿真难以穷举、故障出现到灾难发生时间太短难以及时获取故障数据、系统所处环境变化导致难以判断系统所处的状态等客观原因,使得完备故障库的获取非常困难<sup>[3-4]</sup>。而现实问题是:对于高可靠的复杂系统来讲,被人们已知的预期故障在实际应用中甚少发生,而在线(在轨)发生的往往都是非预期故障。

故障诊断主要包括故障检测与故障识别<sup>[1,5]</sup>。非预期故障诊断是预期故障诊断的扩展。对非预期故障的检测、诊断及处理是复杂系统故障诊断领域的难点,也是故障诊断技术的发展方向。

故障诊断方法通常可分为基于模型驱动的故障诊断、基于知识判决的故障诊断和基于数据驱动的故障诊断三大类<sup>[6]</sup>。从现有的资料分析来看,国内外对非预期故障诊断研究的关注较少,无论从问题本身还是技术实现上都没有形成一个成熟的解决方案<sup>[7-9]</sup>。大多数关于非预期故障的研究重点是基于已知故障模式库进行模式间的识别

\* 收稿日期:2016-07-13

基金项目:国家自然科学基金资助项目(61773021, 61703408);湖南省研究生科研创新资助项目(CX2014B010)

作者简介:陈彧赞(1979—),女,湖南邵东人,博士研究生,E-mail:kasineya@sina.com;

王炯琦(通信作者),男,副教授,博士,硕士生导师,E-mail:wjq\_gfkd@163.com

与知识的推理匹配<sup>[10-11]</sup>。

相对于基于模型驱动的和基于知识判决的故障诊断方法,基于数据驱动的故障诊断方法是直接利用监控系统的数据或状态,采用数据分析、统计决策、深度学习等技术进行故障诊断,不仅可以达到非预期故障检测的目的,而且还有望在完成故障检测后,对故障模式、故障特征以及故障属性进行有效分析,从而实现非预期故障的识别。针对该问题,提出一种数据驱动的非预期故障诊断通用过程模型,提高对复杂系统非预期故障的诊断能力。

## 1 非预期故障诊断内涵及功能

非预期故障诊断可以由四个部分来集成,包括已知故障检测、已知故障识别、未知故障检测、未知故障识别。其基本概念和内涵见表1。

表1 故障诊断的概念和内涵

Tab.1 Notions and connotation of fault diagnosis

	概念	内涵
预期故障	已知故障检测	是否发生故障
诊断	已知故障识别	发生哪类预期故障
非预期故障	未知故障检测	是否发生未知故障
故障诊断	未知故障识别	发生什么样的未知故障

**定义1** 已知故障检测是判别复杂系统是否发生故障的过程。

令 $f$ 为当前待测试数据 $y$ 的故障模式, $f_0$ 表示数据为正常的模式, $F = \{f_i, i = 1, 2, \dots, n_f\}$ 表示具有 $n_f$ 类不同故障模式的已知故障库, $f_i$ 表示第 $i$ 类已知故障。则已知故障检测就是判别待判决的故障 $f$ 是否属于集合 $\{f_0\}$ 的过程,即已知故障检测可以转化为如式(1)所示的假设检验问题。

原假设  $H_0: f \in \{f_0\}$  v. s. 备选假设  $H_1: f \notin \{f_0\}$  (1)

构建预期故障检测的检测统计量  $T^2(y)$ ,在满足检测虚警率(显著性水平)为 $\alpha$ 的前提下,确定拒绝域(即检验的阈值  $T_\alpha^2$ ),得到检测规则1。

**检测规则1:**若  $T^2(y) < T_\alpha^2$ ,则认为原假设  $H_0$  成立;否则,原假设不成立。

**定义2** 已知故障识别是判别该故障是哪类已知故障的过程。

已知故障识别问题是一个典型的最小化寻优问题,可以通过定义待判决故障模式 $y$ 与已知故障集中的所有 $f_i$ 之间的偏离度  $d(y, f_i)$ ,完成有限

集内的最小化寻优问题。

**识别规则1:**若

$$d(y, f_{i_0}) = \min \{d(y, f_i) \mid f_i \in F\} \quad (2)$$

则当前待判决的故障 $y$ 暂时判别为第 $i_0$ 种已知故障模式。

**定义3** 未知故障检测是判别复杂系统是否发生未知故障的过程。

在已知故障识别模块中,暂把当前待判决的故障 $y$ 认为是已知故障集中的第 $i_0$ 种模式;而未知故障检测就是进一步判别以上决策是否正确。已知故障检测的前提是假设实际发生的故障都是在已知故障模式库中的,这意味着一旦复杂系统发生了未知故障,则总将其错误地判断为其中某一类已知故障。

类似于已知故障检测,未知故障检测也可以转化为如式(3)所示的假设检验问题。

原假设  $H_0: f \in \{f_{i_0}\}$  v. s. 备选假设  $H_1: f \notin \{f_{i_0}\}$  (3)

构建未知故障检测的检测统计量  $UFDS(y)$ ,同样在满足检测虚警率(显著性水平)为 $\alpha$ 的前提下,确定拒绝域(即检验的阈值  $UFDS_\alpha$ ),得到检测规则3。

**检测规则2:**若  $UFDS(y) < UFDS_\alpha$ ,则认为  $H_0$  成立;否则,原假设不成立。

未知故障识别需要进一步判断发生的未知故障具有哪些属性和特征,如故障的幅值、故障的时变特征,甚至该故障所对应的硬件模块。广义上来讲,未知故障检测完成之后,对未知故障数据本身的非监督模式识别,包括特征提取、模式聚类 and 物理映射等,以及非预期故障实现预期化以后,预期故障模式库的更新、数据库的更新等都属于未知故障诊断技术所涉及的内容。

但是未知故障诊断的困难之处主要是由于没有未知故障的相关历史信息,无法找到故障数据到故障部件的映射关系(本质上,故障模式就是一种函数对应关系)。因此未知故障诊断的关键是如何“快速”建立认识过程,这个认识包括表层数据特征的认识,也包括数据到物理层的映射认识。对于基于数据驱动的故障诊断方法,可以理解为一旦找到了该故障所属的变量,则实现了未知故障的识别。

**定义4** 未知故障识别是判别该故障属于复杂系统所对应的哪个变量的过程。

显然,未知故障识别也是一个最小化寻优问题,可以通过定义该故障的第 $i$ 个变量对整体系统故障的贡献率  $CR(i)$ ,进而通过计算最大

$\{CR(i)\}_{i=1}^{n_1}$  来实现相应变量的归属度,其中  $n_1$  是测试变量的维数。

识别规则 2:若

$$CR(i_0) = \max \{CR(i)\}_{i=1}^{n_1} \quad (4)$$

则第  $i_0$  个变量判别为相应的故障变量。

## 2 通用过程模型

结合非预期故障诊断内涵,对应非预期故障诊断功能,提出了一种数据驱动的非预期故障诊断多层通用过程模型。该通用过程模型采用四层结构,如图 1 所示。第一层是以已知故障检测判别器构建为核心的预期(已知)故障检测层,主要实现故障检测;第二层为预期(已知)故障识别层,利用检测残差提取故障特征,构建当前故障与已知故障的偏离度以实现已知故障识别;第三层为非预期(未知)故障检测层,构建未知故障检测统计量,完成未知故障检测;第四层为非预期(未知)故障识别层,采用贡献率法分析与当前未知故障最相关的变量,实现基于表层数据特征的故障识别。

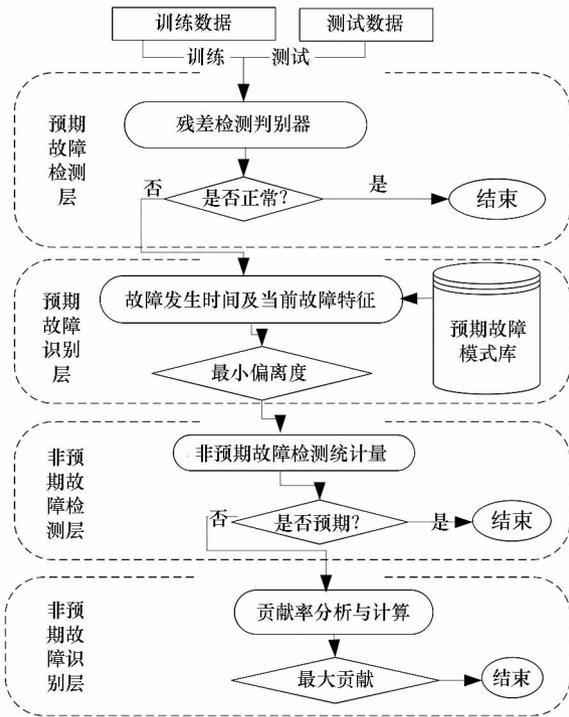


图 1 非预期故障诊断通用过程模型

Fig. 1 General process model for unanticipated fault diagnosis

### 2.1 预期(已知)故障检测层

预期故障检测层的任务是判断被测试数据是否为正常模式。数据驱动故障诊断方法需要构建检测统计量进行故障检测。预期故障检测层本质上就是一个单类判别器。这个判别器经过正常数

据的训练后,获取系统在正常模式下的数据特征,进而完成对测试数据的检测判别。其中涉及两个关键问题:一是残差生成,该残差是构建检测统计量的核心;二是残差评估,就是在给定规则和判别阈值下,进一步将残差转化成可以用于判别的检测统计量。

实际应用中,不同的复杂系统及其相应的监控数据,有不同的残差生成方法。其中,如  $T^2$  统计量判别法适用于平稳数据系统;标称数据平滑检测法适用于能够获得标称数据的非平稳系统,计算量小、检测迅速、检测效果最好;时序建模预测法适用于输出连续和无输入系统,适合模型迭代更新,缺点是预测时间短<sup>[12-13]</sup>。

### 2.2 预期(已知)故障识别层

预期故障识别层的任务是结合预期故障检测层中检测的故障特征(包括故障发生时间及当前故障特征)和预期故障模式库中的故障特征进行匹配,建立各故障模式间的偏离度。其中涉及两个关键问题:一是构建各故障模式间的偏离度;二是对所构建的识别器进行进一步的判别及评估,也就是依据最小准则搜索最小的偏离度,完成预期故障识别。

实际应用中,基于数据驱动的故障诊断方法,主要通过如下两种信息来构建识别器,包括位置分布识别器和方向分布偏离度。相对而言后者是更可靠的故障识别信息,可防止将不同幅值的故障判断为不同模式的故障。

### 2.3 非预期(未知)故障检测层

非预期故障检测层的任务是实现非预期故障的检测,主要通过对非预期故障检测统计量的构建,将当前故障特征方向与所有预期故障模式的故障特征进行逐一匹配,从而实现非预期故障与预期故障的分离。非预期故障检测层本质上就是一个多类判别器。如果当前故障特征与任何一种预期故障的特征都不能匹配,则说明发生了非预期故障。此层的关键问题在于非预期故障检测统计量的构造,其实现原理与预期故障检测层类似。

### 2.4 非预期(未知)故障识别层

非预期故障识别层的任务是对非预期故障检测后,对检测的非预期故障数据进行在线学习和分析,以生成能够表现该数据的故障模式,其作用是学习和概括在未知数据中发现的模式。与预期故障识别不同,非预期故障识别很难找到故障数据到故障部件的映射关系,因此其识别的重点在于建立数据到未知故障或其特征的对应关系,包

括数据层上表层特征的认识和物理层上映射关系的建立等。由于缺乏历史信息、先验知识和对非预期故障认识不充分,一般情况下,建立物理层上的映射关系是相对比较困难的。这里重点分析基于数据层的非预期故障识别,通过计算各变量对整体系统故障的贡献率实现相应变量的归属度,完成非预期故障识别。

### 3 算法实现与算例

根据非预期故障诊断通用过程模型,结合各层所要解决的关键问题,以卫星姿态控制系统为例,来讨论相应算法的实现过程。

值得注意的是,对于其他一般的系统,如机器人系统、大型工业系统等,仍可以结合图1所描述的非预期故障诊断通用过程模型以及本节讨论的相应算法来实现非预期故障的检测与识别。

#### 3.1 卫星姿态控制系统及数据描述

图2给出了卫星姿态控制系统的结构<sup>[4]</sup>。

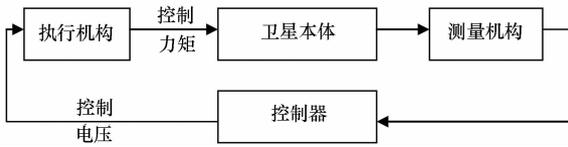


图2 卫星姿态控制系统结构

Fig.2 Structure for satellite's attitude control system

由于卫星姿态控制系统技术结构的复杂性和过程环境的不确定性,实际在轨运行中,系统(特别是其中的测量机构与执行机构)极易出现故障。

考虑卫星姿态控制系统测量机构的输出数据,共有20个批次的的数据。第一个批次是正常数据,正常模式数据是连续但非平稳的,剩余的19个批次用于测试,见表2。所有故障在数据输出上的表现与正常模式有明显区别。图3给出了正常模式下和第一批滚动地球敏感器故障模式下的数据输出对比,其中纵向虚线表示故障发生时刻。每个批次的的数据维数  $n_y = 7$ , 对应7个姿态测量机构  $(E_\phi, E_\theta, S_\phi, S_\theta, g_\phi, g_\theta, g_\psi)^T$ , 见表3。每个批次数据时间为500s,采样间隔1s,即  $m = 500, Y \in \mathbb{R}^{n_y \times m}$ 。

#### 3.2 已知故障检测算法实现

对于所提供的数据,由于数据的非平稳性(如图3所示),已知故障检测首先需要对数据进行取趋消噪的处理,得到用于故障检测的平稳残差。

表2 不同故障模式下的数据描述

Tab.2 Batch number description of monitoring data

序号	故障类型	发生时间/s
1	正常模式	
2	第一批滚动地球敏感器故障	211
3	第二批滚动地球敏感器故障	364
4	第三批滚动地球敏感器故障	254
5	第四批滚动地球敏感器故障	254
6	第一批俯仰地球敏感器故障	440
7	第二批俯仰地球敏感器故障	240
8	第三批俯仰地球敏感器故障	170
9	第四批俯仰地球敏感器故障	351
10	第一批滚动太阳敏感器故障	395
11	第二批滚动太阳敏感器故障	368
12	第三批滚动太阳敏感器故障	78
13	第一批俯仰太阳敏感器故障	352
14	第二批俯仰太阳敏感器故障	70
15	第一批滚动陀螺故障	328
16	第二批滚动陀螺故障	95
17	第一批俯仰陀螺故障	392
18	第二批俯仰陀螺故障	125
19	第一批偏航陀螺故障	386
20	第二批偏航陀螺故障	144

对于非平稳正常模式下的训练数据  $Y = (y_1, y_2, \dots, y_m) \in \mathbb{R}^{n_y \times m}$ , 其中  $n_y$  为输出数据维数,  $m$  为样本容量。利用标称数据平滑检测法,将  $Y$  分解为非平稳趋势项和平稳残差项<sup>[14-15]</sup>。

$$Y = \hat{Y} + \tilde{Y} \quad (5)$$

记  $\hat{y}_i$  和  $\tilde{y}_i$  分别为  $\hat{Y}$  和  $\tilde{Y}$  的第  $i$  列,计算残差的协方差矩阵。

$$\Sigma = \frac{1}{m-1} \tilde{Y} \tilde{Y}^T \quad (6)$$

同时计算测试数据  $y$  的检测残差。

$$r = y - \hat{y}_i \quad (7)$$

由式(6)和式(7)构造  $T^2$  统计量。

$$T^2(y) = r^T \Sigma^{-1} r \quad (8)$$

在训练数据样本服从多元正态分布的前提下,当检测虚警率(显著性水平)为  $\alpha$  ( $\alpha = 0.05$ ) 时,姿态测量机构所对应数据的检验阈值为:

$$T_\alpha^2 = \frac{n_y(m^2 - 1)}{m(m - n_y)} F_\alpha(n_y, m - n_y) = 14.3979 \quad (9)$$

依据检测规则1,对表2中的所有测试数据进行已知故障检测,检测结果见表4。由表4可知,故障检测及时,检测效果比较明显。检测结果

包含了故障的发生时间、检测虚警率、漏检率和故障发生时刻的故障样本方向  $\mathbf{r}$ 。表 4 中的故障检测虚警率是误判为故障的样本量与整个数据样本量之比;漏检率是误判为正常的样本量与整个数据样本量之比。

表 3 数据变量描述

Tab. 3 Data variable description

变量代号	传感器	变量/ (°)	变量代号	传感器	变量/ (°)
$y_1$	滚动地球敏感器	$E_\phi$	$y_5$	滚动陀螺	$g_\phi$
$y_2$	俯仰地球敏感器	$E_\theta$	$y_6$	俯仰陀螺	$g_\theta$
$y_3$	滚动太阳敏感器	$S_\phi$	$y_7$	偏航陀螺	$g_\psi$
$y_4$	俯仰太阳敏感器	$S_\theta$			

### 3.3 已知故障识别算法实现

经过已知障检测层后,得到当前故障的样本方向  $\mathbf{r}$ ,见表 4。而已知故障识别的任务就是利用检测残差的位置分布或方向分布提取故障特征,用于构建故障识别的偏离度。利用方向信息作为构建故障识别偏离度的信息量。记  $\mathbf{T}_i$  为对应于故障模式  $f_i$  的特征方向 ( $i=1,2,\dots,n_f$ ),  $\mathbf{r}_{ij}$  ( $j=1,2,\dots,n_i$ ) 为该故障相应的样本方向,则故障特征方向与样本方向的关系为:

$$\mathbf{T}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{r}_{ij} / \left\| \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{r}_{ij} \right\| \quad (10)$$

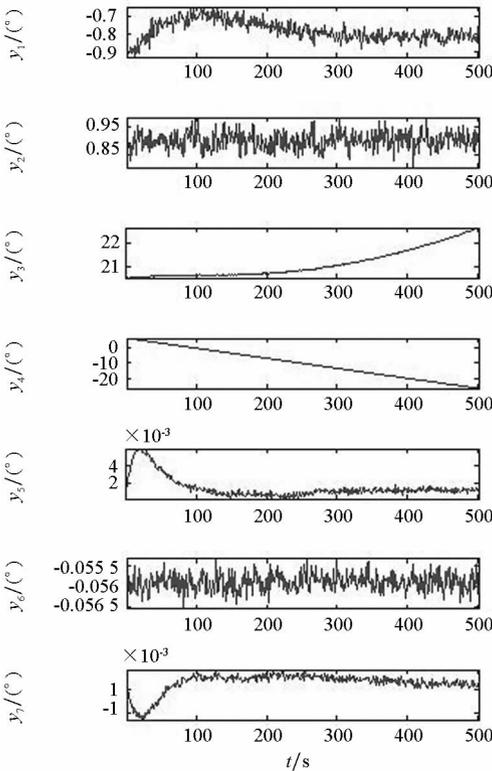
记  $\theta(\mathbf{r}, \mathbf{T}_i)$  为  $\mathbf{r}$  和已知故障模式库中的第  $i$  个故障模式  $f_i$  对应的特征方向  $\mathbf{T}_i$  的方向夹角,即  $\theta(\mathbf{r}, \mathbf{T}_i) = \arccos[|\mathbf{r}^T \mathbf{T}_i| / (\|\mathbf{r}\| \cdot \|\mathbf{T}_i\|)]$

$$(11)$$

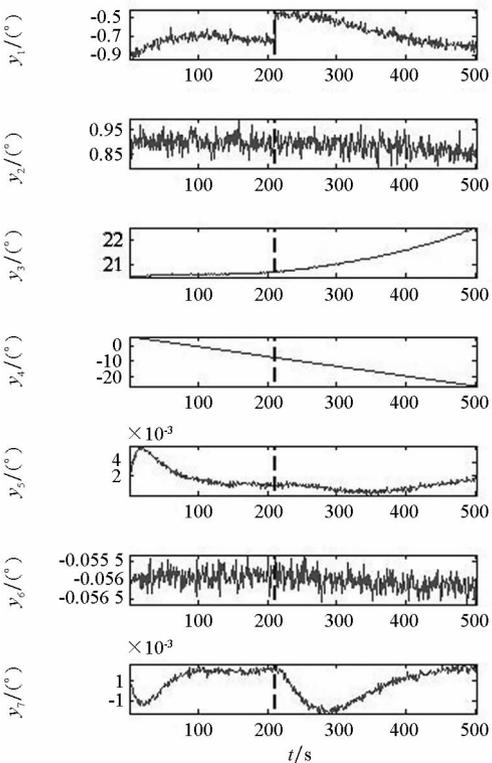
若当前故障样本方向  $\mathbf{r}$  与第  $i$  个故障模式所对应的特征方向  $\mathbf{T}_i$  的夹角较小,则当前故障可判别为第  $i$  种故障模式。同理,若  $\theta(\mathbf{T}_i, \mathbf{T}_j)$  越大,则第  $i$  种故障模式和第  $j$  种故障模式越容易识别。

对表 4 中的已知故障检测,初始阶段,设预期故障模式库为空,则表 4 中第 2 批数据中的故障时间  $t = 212$  s,将当前故障的样本方向单位化作为第 1 种故障模式的特征方向,即  $\mathbf{T}_1 = (0.979, 0.012, -0.134, -0.067, 0.012, 0.156, -0.022)^T$ 。而对于第 3 批次数据,故障时间为  $t = 365$  s,当前故障的样本方向  $\mathbf{r} = (12.131, 0.289, -0.238, 1.002, 0.602, -1.632, 1.649)^T$ 。

依据识别规则 1,暂时判断第 3 批数据的故障为第 1 种预期故障模式,并将当前故障样本方向提交至未知故障检测层。



(a) 正常模式  
(a) Normal pattern



(b) 故障模式  
(b) Fault pattern

图 3 正常模式数据与故障模式数据对比

Fig. 3 Data comparison between the normal pattern and the fault pattern

表4 已知故障检测结果——预期(已知)故障检测层  
Tab.4 Calculation result of anticipated fault detection—anticipated fault detection layer

序号	是否 正常	虚警 率/%	漏检 率/%	发生 时间/s	当前故障样本方向 $r$ (第1~7为分量)						
1	是	4.2	0	0	0	0	0	0	0	0	0
2	否	3.1	1.1	211+1	11.621	0.189	-1.667	0.906	0.132	2.019	-0.323
3	否	3.3	1.2	364+1	12.131	0.289	-0.238	1.002	0.602	-1.632	1.649
4	否	4.2	1.3	254+1	11.226	0.389	-1.323	-0.909	0.097	1.932	-0.225
5	否	5.4	1.2	254+1	-143.513	-0.243	-1.601	-1.019	-0.798	0.347	0.344
6	否	4.1	1.0	440+2	-1.821	-3.569	0.236	0.722	0.238	0.354	-1.751
7	否	4.3	3.4	240+1	0.945	320.353	0.321	0.467	-0.059	0.221	0.362
8	否	5.4	1.2	170+1	-1.922	10.789	-0.176	-0.532	-0.787	2.401	-1.015
9	否	2.3	1.3	351+1	0.513	11.354	-0.789	1.876	1.776	0.278	-0.534
10	否	2.3	1.1	395+1	0.958	0.667	-2306.734	1.302	-1.041	0.567	-1.843
11	否	3.2	1.5	368+1	-0.676	-0.120	-2285.512	-0.911	0.567	0.354	-0.755
12	否	4.4	0.3	78+1	0.822	-0.732	-2194.920	1.923	-0.298	0.734	-0.365
13	否	4.2	1.2	352+1	-0.029	1.560	-0.654	1662.656	1.296	-0.311	0.474
14	否	6.1	0.3	70+1	-0.086	1.233	1.644	-159.124	1.023	0.632	-0.731
15	否	2.0	6.2	328+1	1.743	-1.633	-2.721	-0.732	13.676	0.029	-0.897
16	否	1.1	1.1	95+1	-0.443	1.654	-0.768	-0.602	15.598	-0.954	-0.921
17	否	3.0	8.5	392+1	0.842	-1.298	0.388	-1.432	-0.564	13.003	0.0679
18	否	5.3	3.5	125+1	-0.455	-0.121	-0.019	1.365	-1.013	13.821	0.122
19	否	4.4	7.3	386+1	-1.229	-1.001	0.018	-0.596	0.421	-0.811	15.976
20	否	3.2	6.3	144+1	0.312	0.392	0.127	1.234	-1.755	-0.563	14.778

3.4 未知故障检测算法实现

在已知故障识别层中,暂把当前故障判别为某种已知的故障模式;而在未知故障检测层,要进一步确定其是否为未知故障。未知故障检测的实现原理类似于已知故障检测。

对于当前故障样本方向  $r$  和第  $i$  种已知故障模式特征方向  $T_i$ ,构建未知故障检测统计量。

$$UFDS(r, T_i) = \|r\| (1 - |\cos(r, T_i)|) / \sqrt{T_i^T \Sigma T_i} \tag{12}$$

其中,  $\Sigma$  为平滑数据残差的协方差矩阵,见式(6)。

可以证明,在原假设成立的前提下<sup>[16]</sup>,即当前故障样本方向  $r$  来自于第  $i$  种已知故障模式,未知故障检测统计量近似服从标准正态分布。考虑到  $UFDS(r, T_i)$  的非负性,当检测虚警率(显著性水平)为  $\alpha$  ( $\alpha = 0.05$ ) 时,对应的未知故障检验阈值为:

$$u_\alpha = u_{0.05} = 2.2326 \tag{13}$$

依据检测规则2,对经过已知故障识别层后的所有故障进行未知故障的检测。如对于表4中的第2批数据,由于初始状态,已知故障模式库为空,则第2批数据的故障必为未知故障;对于第3批数据,由已知故障识别层,暂时判别其为第1种已知故障模式,进而利用式(12),计算检测统计量

$$UFDS(r, T_1) = 0.1397 < 2.2326 \tag{14}$$

从而,依据检测规则2,即认为第3批数据的故障与第1类已知故障模式相同,判别其为已知故障,并利用故障样本方向  $r$  更新所识别的已知故障的特征方向。表4中所有测试数据的未知故障检测及故障特征方向的更新结果见表5。从表5可以看出,提取故障特征方向,利用式(12)构建未知故障检测统计量,确实能实现未知故障与已知故障的识别。

表 5 未知故障检测结果——非预期(未知)故障检测层

Tab.5 Calculation result of unanticipated fault detection—unanticipated fault detection layer

序号	是否预期	故障模式代码	对应故障模式的特征方向更新结果						
1	正常模式	0	0.000	0.000	0.000	0.000	0.000	0.000	0.000
2	否	1	0.979	0.012	-0.134	-0.067	0.012	0.156	-0.022
3	是	1	0.998	0.028	-0.059	0.001	0.019	0.028	0.055
4	是	1	0.987	0.003	0.022	0.011	0.011	0.002	0.003
5	是	1	0.956	0.002	0.003	0.001	-0.003	-0.003	0.021
6	否	2	0.340	-0.898	0.055	0.196	0.056	0.067	-0.389
7	是	2	0.022	0.943	0.001	0.002	0.008	0.017	0.003
8	是	2	0.001	0.920	0.003	0.003	0.101	0.004	0.043
9	是	2	0.002	0.951	0.002 6	0.028	0.031	0.014	0.033
10	否	3	0.002	0.016	-0.987	0.002	0.003	0.004	0.103
11	是	3	0.001	0.026	-0.945	0.017	0.026	0.024	0.083
12	是	3	0.002	0.016 8	-0.950	0.089	0.032	0.003 7	0.152
13	否	4	0.092	0.002	0.123	0.899	0.141	0.078	0.023
14	是	4	0.001	0.012	0.093	0.979	0.081	0.032	0.014
15	否	5	0.112	-0.121	-0.139	-0.045	0.926	0.002	-0.036
16	是	5	0.034	0.009	-0.132	-0.024	0.949	-0.023	-0.065
17	否	6	0.056	-0.102	0.033	-0.141	-0.054	0.908 2	0.031
18	是	6	0.021	-0.035	0.041	0.003	-0.036	0.916	0.041
19	否	7	-0.038	-0.046	0.005	-0.043	0.032	-0.045	0.946
20	是	7	-0.074	-0.068	0.054	0.043	-0.123	-0.026	0.969

3.5 未知故障识别算法实现

基于数据驱动的未知故障识别方法,主要是要利用贡献率的归属度,来判别与当前未知故障最相关的变量,进而实现未知故障的识别。

对式(6)中检测残差的协方差矩阵  $\Sigma$  进行正交相似对角化,即

$$\Sigma = P^T \text{diag}(\lambda) P \tag{15}$$

其中,  $\lambda = (\lambda_1, \dots, \lambda_{n_y})$ ,  $P = (p_1, \dots, p_{n_y})$ ,  $\lambda_i$ ,  $p_i$  ( $i = 1, 2, \dots, n_y$ ) 为相应的特征值和特征向量。记  $p_{ji}$  表示  $p_i$  的第  $j$  个分量,令  $t_i = r^T p_i$ ,  $r_j$  表示当前故障模式的特征方向  $T$  的第  $j$  个分量,  $j = 1, 2, \dots, n_y$ 。定义第  $j$  个变量对当前故障特征方向  $T$  的贡献率为:

$$CR(j) = \sum_{i=1}^{n_y} (t_i r_j p_{ji} / \lambda_i) \tag{16}$$

从数据层的未知故障识别来讲,显然,贡献率最大的变量就是故障变量。如果是传感器故障,那么贡献率最大变量对应的传感器就是出现故障的硬件。依据识别规则 2,对表 5 中的未知故障检测结果进行进一步的识别,结果见表 6。如对于图 3 中滚动地球敏感器故障模式下的数据,尽管从数据输出表现上,分量  $y_7$  (即偏航陀螺)也出现了很大的差别,然而由于分量  $y_1$  的贡献率远大于分量  $y_7$  的,故对应故障的传感器识别为滚动地球敏感器故障。从表 6 可知,未知故障对应的故障变量识别正确,达到了数据层的未知故障识别效果。

表6 未知故障识别结果——非预期(未知)故障识别层  
Tab.6 Calculation result of unanticipated fault detection—  
unanticipated fault identification layer

序号	是否 预期	故障模 式代码	对应传感器
1	非故障	0	
2	否	1	滚动地球敏感器
3	是	1	滚动地球敏感器
4	是	1	滚动地球敏感器
5	是	1	滚动地球敏感器
6	否	2	俯仰地球敏感器
7	是	2	俯仰地球敏感器
8	是	2	俯仰地球敏感器
9	是	2	俯仰地球敏感器
10	否	3	滚动太阳敏感器
11	是	3	滚动太阳敏感器
12	是	3	滚动太阳敏感器
13	否	4	俯仰太阳敏感器
14	是	4	俯仰太阳敏感器
15	否	5	滚动陀螺
16	是	5	滚动陀螺
17	否	6	俯仰陀螺
18	是	6	俯仰陀螺
19	否	7	偏航陀螺
20	是	7	偏航陀螺

## 4 结论

将复杂系统非预期故障作为主要诊断对象,分析了非预期故障诊断的基本原理。设计了一种非预期故障诊断的通用过程模型,为非预期故障诊断提供了框架支撑。针对检测数据特点,构建已知故障检测统计量,实现故障的检测;利用测试数据的方向分布,构建识别偏离度,实现已知故障识别;利用当前故障样本方向和已知故障的模式特征方向构造角度相似性统计量,实现未知故障的检测;通过奇异值分解,获得每个变量的故障贡献率,实现对复杂系统未知故障的识别。以卫星姿态控制系统为例,验证了非预期故障诊断通用过程模型的有效性。

## 参考文献 (References)

[1] Isermann R, Füssl D. Supervision, fault-detection and fault-diagnosis methods [J]. Journal of Control Engineering Practice, 1997, 5(5): 639–652.

[2] Chiang L H, Russell E L, Braatz R D. Fault detection and diagnosis in industrial system [M]. UK: Springer, London, 2001.

[3] Jin L, Ko S, Ryoo C K. Fault tolerant control for satellites with four reaction wheels [J]. Control Engineering Practice, 2008, 16(10): 1250–1258.

[4] 屠善澄. 卫星姿态动力学与控制[M]. 北京: 中国宇航出版社, 2001.

TU Shancheng. Satellite attitude dynamics and control [M]. Beijing: Chinese Astronautic Publishing House, 2001. (in Chinese)

[5] Ding S X. Data-driven design of fault diagnosis and fault-tolerant control systems [M]. UK: Springer, London, 2014.

[6] 何章鸣. 非预期故障的数据驱动诊断方法研究[D]. 长沙: 国防科技大学, 2015.

HE Zhangming. Research on data driven diagnosis methods for unanticipated fault [D]. Changsha: National University of Defense Technology, 2015. (in Chinese)

[7] Kojima K, Ito K. Autonomous learning of novel patterns by utilizing chaotic dynamics [C]//Proceedings of IEEE International Conference on Systems, Man, and Cybernetics, 1999, 1: 284–289.

[8] Perner P. Concepts for novelty detection and handling based on a case-based reasoning process scheme [C]//Proceedings of the 7th Industrial Conference on Data Mining, 2007.

[9] Singh S, Tu H Y, Donat W, et al. Anomaly detection via feature-aided tracking and Hidden Markov models [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans, 2009, 39(1): 144–159.

[10] Tom B, Tom J. Anomaly detection for advanced military aircraft using neural networks [C]//Proceedings of IEEE Aerospace Conference, 2001, 6: 3113–3123.

[11] Zhang B, Sconyers C, Byington C, et al. Anomaly detection: a robust approach to detection of unanticipated faults [C]//Proceedings of International Conference on Prognostics and Health Management, 2008: 1–8.

[12] Wang J Q, Wang D Y, He Z M, et al. Data-driven diagnosis for unanticipated fault by a general process model [C]//Proceedings of Chinese Automation Congress, 2013.

[13] 胡小平, 张丽娟, 王艳梅, 等. 液体火箭发动机故障检测和诊断中的数据挖掘策略的分析[J]. 国防科技大学学报, 2005, 27(3): 1–5.

HU Xiaoping, ZHANG Lijuan, WANG Yanmei, et al. The analysis of data mining strategy in fault detection and diagnosis of the liquid rocket engine [J]. Journal of National University of Defense Technology, 2005, 27(3): 1–5. (in Chinese)

[14] Wang J Q, He Z M, Pan X G, et al. Fault diagnosis for satellite's attitude determination system based on model error prediction and EMD [C]//Proceedings of American Control Conference, 2013: 4337–4342.

[15] Wang Z M, Yi D Y, Duan X J, et al. Measurement data modeling and parameter estimation [M]. USA: CRC Press, 2012.

[16] 茆诗松, 王静龙, 濮晓龙. 高等数理统计[M]. 2版. 北京: 高等教育出版社, 2006.

MAO Shisong, WANG Jinglong, PU Xiaolong. Advanced mathematical statistics [M]. 2nd ed. Beijing: Higher Education Press, 2006. (in Chinese)