

## 基于分层DSmT的多故障诊断方法

李向军<sup>1</sup>, 庄晓翔<sup>2</sup>, 于霞<sup>2</sup>, 许鹏<sup>2</sup>

(1. 大连海洋大学 信息工程学院, 辽宁 大连 116026; 2. 东北大学 信息科学与工程学院, 沈阳 110004)

**摘要:** 针对现有故障诊断方法难以诊断涵盖多种不同类型故障的问题, 提出一种基于分层DSmT的多故障诊断方法. 利用主元凝聚层聚类方法实现证据聚类, 将辨识框架分成若干个子框架; 利用证据主元将BP神经网络所生成的各种故障模式的基本概率赋值函数在不同辨识框架下重新分配; 利用DSmT对子框架下的证据进行融合并得出诊断结果. 仿真实验结果表明, 所提出的方法能将不同类型故障从辨识框架中分离出来, 提高多故障诊断结果的可靠性, 减少计算量, 提高诊断效率.

**关键词:** 分层DSmT; 多故障; 故障诊断; 证据主元

**中图分类号:** TP277

**文献标志码:** A

## Method of multiple faults diagnosis based on hierarchical DSmT

LI Xiang-jun<sup>1</sup>, ZHUANG Xiao-xiang<sup>2</sup>, YU Xia<sup>2</sup>, XU Peng<sup>2</sup>

(1. College of Information Engineering, Dalian Maritime University, Dalian 116026, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China. Correspondent: YU Xia, E-mail: yuxia@ise.neu.edu.cn)

**Abstract:** Aiming at that existing fault diagnosis methods are difficult to diagnose faults that cover many different types, a method based on hierarchical DSmT is proposed. Fault elements in the identification framework are separated into different levels by hierarchical clustering based on the current evidence. Then the basic probability assignment function is reassigned, which is constructed based on the output of the BP neural network according to the principal components of evidences in different levels. Finally, DSmT is used to combine the different independent evidences in the same level and draw a conclusion. The diagnostic tests show that the proposed method not only recognizes different faults from the framework, but also reduces the calculation amount, which can effectively improve the accuracy and efficiency of multi-faults diagnosis.

**Keywords:** hierarchical DSmT; multi-faults; fault diagnosis; principal components of evidences

## 0 引言

以钢铁、有色金属等连续轧制生产为代表的一类快速复杂工业过程一旦出现故障, 极易导致连锁反应, 进而出现多故障并发的局面<sup>[1-2]</sup>. 以轧钢过程为例: 连续轧制生产线是钢铁工业以及有色行业的核心生产装备, 其检测数据有190多个, 并且检测数据具有非线性、动态性、多尺度、强冗余等特性<sup>[3-4]</sup>. 当系统发生故障时, 其故障模式与征兆信号之间表现出错综复杂的关系, 所以对于这样的复杂系统, 多故障更能反映实际故障发生情况. 通常情况下, 在实际生产过程中几乎任何一个系统都有可能发生多故障.

根据多故障的“故障-征兆”间的关系可将多故障分为3种类型: 独立多故障、耦合多故障以及并发多

故障. 独立多故障, 即多个故障同时发生, 但各个故障之间是相互独立的, 不相互影响, 这是多故障诊断中相对简单的一种情况. 耦合多故障, 表现为故障征兆之间具有无法去除的相关性, 故障征兆与故障类别的对应关系不明确, 通常难以按一般的数学方法解耦成互不相关的单故障, 该部分是多故障诊断方法研究的重点, 也是难点之一. 并发多故障, 是指上述两类故障同时发生的情况.

由于多故障具有随机性、耦合性、复杂性等特性, 使其“故障-征兆”对应关系较单故障更为复杂, 仅利用单一传感器信息很难准确全面反映系统的运行情况, 进而无法实现故障的诊断. 目前, 解决这一问题的主要方法是利用多传感器信息融合技术, 通过发挥各

**收稿日期:** 2015-05-01; **修回日期:** 2016-01-05.

**基金项目:** 国家自然科学基金项目(61374137).

**作者简介:** 李向军(1963—), 女, 副教授, 博士, 从事智能控制、最优化控制等研究; 庄晓翔(1990—), 女, 硕士生, 从事信息融合、多故障诊断方法的研究.

传感器信息冗余、互补、协同的优势,将来自多源的信息进行融合,获得最终决策,进而实现故障诊断。

Dempster-Shafe 证据理论 (DST) 是目前广泛应用于多传感器系统的信息融合方法。张翼等<sup>[5]</sup>提出了基于 DST 在不同辨识框架下实现传感器多故障的诊断方法,该方法通过粗化和细化运算能有效诊断出传感器所发生的单故障和多故障。但由于 DS 模型的辨识框架要求所有元素都是相互排斥的,即任意元素之间的交集必为空集,使得该方法只能用于诊断单故障和独立多故障发生的情况,不能实现对耦合故障以及并发多故障的诊断。

针对 DST 不能有效诊断复杂多故障的问题,文成林等<sup>[6]</sup>和 Jiang 等<sup>[7]</sup>将 DSMT (Dezert-Smarandache 理论)<sup>[8-9]</sup>应用于复杂多故障诊断中,并以旋转机械的多故障为例,验证了该方法的有效性。DSMT 是将似是而非和自相矛盾的推理方法应用于信息融合中的一种新的理论。DSMT 不仅可以有效表示和处理不确定以及高冲突信息,而且其辨识框架中的元素不再要求是互相排斥的。因此,在 DSMT 模型下可利用元素的交和补来表示复杂多故障。在利用 DSMT 实现融合过程中,如何保证辨识框架元素信度分配客观化是技术难点<sup>[10]</sup>。通过将基于特征层融合的初步诊断结果转换为各故障模式的信度分配,能降低信度分配的复杂性,实现信度分配的客观性。此外,由于 DSMT 组合规则的局限性,当辨识框架中的元素增加时,其组合运算次数将以指数幂的形式增加,计算量庞大,使得故障分离难度增大。目前,解决该问题的主流思想是将辨识框架中的元素按照某种规则减少或分层,通过近似计算得出结论。如: Tessem<sup>[11]</sup>提出了著名的  $k-l-x$  方法; Denocux<sup>[12]</sup>提出了层次化聚类方式以实现 BPA 内层近似和外层近似; 李新德等<sup>[13]</sup>提出了基于分层递阶 DSMT 的近似推理融合方法。

本文提出一种基于分层 DSMT 的多故障诊断方法。该方法通过主元凝聚层证据聚类将利用神经网络获取的特征层初步诊断结果实现分层聚类,进而将辨识框架分成若干个辨识子框架,而同一子框架下的故障为单故障或耦合故障,不同子框架之间的故障为独立多故障。然后在不同的子框架下,根据证据主元将基本概率赋值函数重新分配后再利用 DSMT 进行融合,进而得出诊断结果。

## 1 DSMT 融合理论

### 1.1 DSMT 基本概念

#### 1) 广义辨识框架。

设  $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$  是一个包含  $n$  个完备命题的非空有限集合,则称  $\Theta$  为广义辨识框架。

#### 2) 超幂集。

DSMT 的建立是基于 Dedekind 格子模型  $D^\Theta$ , 也称其为框架  $\Theta$  的超幂集空间。令  $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$  是一个包含  $n$  个完备命题的有限集合,超幂集的定义为: 由  $D^\Theta$  中的命题, 以及通过  $\cup$  和  $\cap$  的运算组成的所有复合命题的集合。

#### 3) 广义基本概率赋值函数。

在一个广义辨识框架  $\Theta$  下, 如果映射  $m(\cdot): D^\Theta \rightarrow [0, 1]$ , 满足以下条件:  $m(\emptyset) = 0$ ,  $m(A) > 0$  且  $\sum_{A \in D^\Theta} m(A) = 1$ , 则称  $m(A)$  为命题  $A$  的广义基本概率赋值函数 (GBPA), 也可称为质量函数。

## 1.2 DSMT 融合规则

#### 1) 自由 DSMT 融合规则。

对于自由 DSMT 模型,  $\Theta$  是事件的完备集, 包含事件的所有可能假设  $\theta_i$ ,  $i = 1, 2, \dots, n$ , 除此之外  $D^\Theta$  不添加任何其他约束。其组合规则如下: 假设在广义辨识框架  $\Theta$  上有相互独立的  $\kappa$  个证据, 它们的 GBPA 分别为  $m_1, m_2, \dots, m_\kappa$ , 当同时作用时, 对于给定的  $A \in D^\Theta$ , 有

$$m(A) = \sum_{\substack{X_1, X_2, \dots, X_\kappa \in D^\Theta \\ X_1 \cap X_2 \cap \dots \cap X_\kappa = A}} \prod_{i=1}^{\kappa} m_i(X_i). \quad (1)$$

#### 2) 混合 DSMT 融合规则。

在某些特殊的融合问题中, 有一部分  $\theta_i$  本身是互斥的, 为了更符合实际情况, 可以将这些互斥约束添加到模型中, 构成混合 DSMT 模型。其组合规则如下: 假设在广义辨识框架  $\Theta$  上有相互独立的  $\kappa$  个证据, 它们的 GBPA 分别为  $m_1, m_2, \dots, m_\kappa$ , 当同时作用时, 对于给定的  $A \in D^\Theta$ , 有

$$m(A) = \delta(A)[S_1(A) + S_2(A) + S_3(A)], \quad (2)$$

其中  $\delta(A)$  是集合  $A$  的特征非空函数, 当  $A \notin \emptyset$  时  $\delta(A) = 1$ , 否则  $\delta(A) = 0$ 。这里,  $\emptyset = \{\emptyset_\mu, \emptyset\}$ ,  $\emptyset_\mu$  是  $D^\Theta$  中由于受到约束而被强制为空的所有集合,  $\emptyset$  是经典或通常意义上的空集。  $S_1(A)$ 、 $S_2(A)$ 、 $S_3(A)$  的定义如下:

$$S_1 = \sum_{\substack{X_1, X_2, \dots, X_\kappa \in D^\Theta \\ X_1 \cap X_2 \cap \dots \cap X_\kappa = A}} \prod_{i=1}^{\kappa} m_i(X_i), \quad (3)$$

$$S_2 = \sum_{\substack{X_1, X_2, \dots, X_\kappa \in \emptyset \\ [u=A] \vee [(u \in \emptyset) \wedge (A=I_t)]}} \prod_{i=1}^{\kappa} m_i(X_i), \quad (4)$$

$$S_3 = \sum_{\substack{X_1, X_2, \dots, X_\kappa \in D^\Theta \\ X_1 \cup X_2 \cup \dots \cup X_\kappa = A \\ X_1 \cap X_2 \cap \dots \cap X_\kappa = \emptyset}} \prod_{i=1}^{\kappa} m_i(X_i). \quad (5)$$

其中:  $u = u(X_1) \cup u(X_2) \cup \dots \cup u(X_\kappa)$ ,  $u(X)$  是组

成  $X$  的所有  $\theta_i$  的并集,  $I_t = \theta_1 \cup \theta_2 \cup \dots \cup \theta_n$  表示完全未知.

## 2 分层规则

本文结合主元思想和传统凝聚层次聚类算法的优势, 提出一种基于主元凝聚层证据聚类的方法, 进而将广义辨识框架中的元素进行分层.

### 2.1 主元凝聚层证据聚类算法

应用分层融合规则时, 需先按照某种方法将广义辨识框架进行分层, 而分层的好坏决定了融合结果的准确程度. 本文提出的主元凝聚层证据聚类算法是一种根据证据主元与证据间的相似度将证据分层聚类, 进而将广义辨识框架进行分层的方法, 其具体算法流程如图1所示.

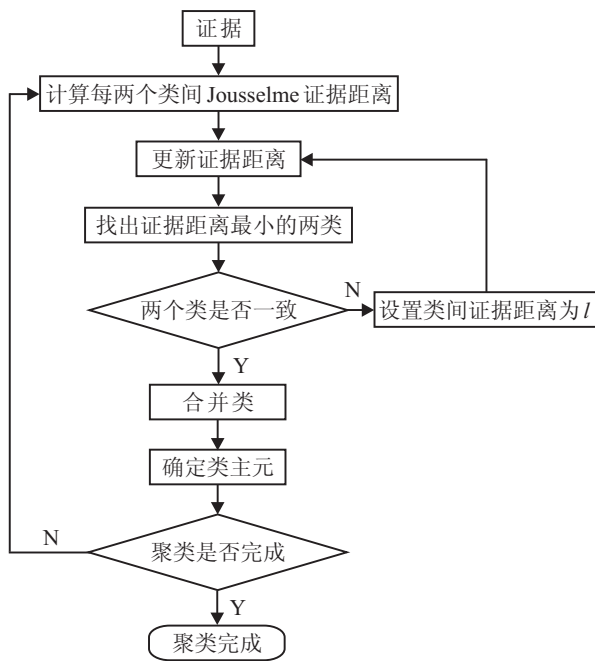


图1 主元凝聚层证据聚类算法流程

该算法首先利用特征层信息融合方法所获取的证据, 选择出每组证据主要支持的故障模式, 即证据主元. 然后按照证据组间的证据距离由小到大的顺序将具有相同证据主元的证据聚成一类. 根据证据聚类的思想<sup>[14]</sup>, 这样聚类之后的同类证据支持的是同一种故障模式, 而不同类证据支持的是不同种故障模式. 如果聚类的类别数为  $m$ , 则表示发生了  $m$  种故障模式. 最后, 根据每类证据的证据主元将不同类别进行合并, 即可得到具有物理意义的广义辨识子框架. 以多故障诊断为例, 通过该方法得到了广义辨识子框架, 同一框架之间的故障可能发生单故障或耦合故障, 不同框架之间的故障可能发生独立多故障, 即实现了将独立多故障、耦合故障从广义辨识框架中分离出来. 此外, 每个辨识子框架中的元素较原框架减少, 进而可有效降低信息融合过程中计算的复杂度.

### 2.2 主元凝聚层证据聚类概念

结合图1所述的算法流程, 简要说明主元凝聚层证据聚类算法中几个重要概念.

#### 1) 证据主元.

一组非空证据, 有  $n$  个非全集焦元, 依据其信度从大到小排序, 有  $A^1, A^2, \dots, A^p, A^{p+1}, \dots, A^n$ . 称前  $p$  个焦元为证据的主焦元, 如果这  $p$  个焦元的信度值满足以下两个条件:

$$\textcircled{1} \frac{m(A^1)}{m(A^i)} \leq \gamma, \gamma \geq 1; i = 1, 2, \dots, p; \quad (6)$$

$$\textcircled{2} m(A^1) - m(A^p) < m(A^p) - m(A^*). \quad (7)$$

其中

$$\begin{cases} m(A^*) = m(A^{p+1}), p < n; \\ m(A^*) = 0, p = n. \end{cases}$$

则证据主元即为这  $p$  个主元的并集, 记为  $LE = A^1 \cup A^2 \cup \dots \cup A^p$ , 其中  $\gamma \in 1 \sim 10$ .

#### 2) 类间的 Joussemle 证据距离.

采用全链接规则时, 两个证据类间的证据距离采用下式计算:

$$d_{BPA}(r, s) = \max(d_{BPA}(e_{ri}, e_{sj})). \quad (8)$$

其中:  $e_{ri}$  为证据类  $C_r$  ( $C_r$  中的证据组数为  $n_r$ ) 中第  $i$  组证据,  $e_{sj}$  为证据类  $C_s$  ( $C_s$  中的证据组数为  $n_s$ ) 中的第  $j$  组证据,  $i \in (1, 2, \dots, n_r), j \in (1, 2, \dots, n_s)$ . 式(8)中,  $d_{BPA}$  为 Joussemle 证据距离<sup>[15]</sup>, 其计算公式为

$$d_{BPA}(e_1, e_2) = \sqrt{\frac{\langle e_1, e_1 \rangle + \langle e_2, e_2 \rangle - 2 \langle e_1, e_2 \rangle}{2}}. \quad (9)$$

其中:  $e_1, e_2$  分别是证据  $e_1$  和  $e_2$  的矢量形式;  $|\cdot|$  为求模计算.  $d_{BPA} \in [0, 1]$ ,  $d_{BPA}$  越大, 表示两证据间的距离越大, 接近性程度越小, 差异性程度越大.

#### 3) 一致性检验.

假设两个类的主元分别为  $A$  和  $B$ , 若  $A \cap B \neq \emptyset$ , 则两个类一致; 若  $A \cap B = \emptyset$ , 则两个类不一致.

一致性检验的目的在于消除可能存在的隐藏冲突以避免错误聚类. 只有两个类主元交集不为空时, 两个类才能合并; 若两个类主元交集为空时, 则说明待合并的两类不一致, 不能合并. 此时需要直接将衡量两类邻近度大小的证据距离更新为1, 说明待合并两类完全不一致, 不能合并. 此时算法直接跳出循环, 终止合并. 这样, 当所有类两两之间的距离为1时, 聚类完成, 当前聚类的个数即为最终聚类别数.

## 3 基于分层DSmT的多故障诊断系统结构

本文提出的基于分层DSmT的多故障诊断系统结构如图2所示. 选择系统的多个关键部位安装多个传感器组成多传感器系统. 首先将传感器采集到

的数据利用时域分析方法提取传感器信号的幅值特征;然后分别将各传感器的特征信号输入到特征层融合系统中,获得特征级初步诊断结果.鉴于反向传播(BP)神经网络优异的非线性映射能力、学习能力和其在故障诊断领域的广泛应用,本文采用BP神经网络获取特征级诊断结果.先将每一个故障样本利用BP神经网络诊断后的结果作为DSmT的一个独立证据;然后应用主元凝聚层聚类方法将多组证据聚类;最后采用分层DSmT融合规则进行证据融合,得出诊断结果.

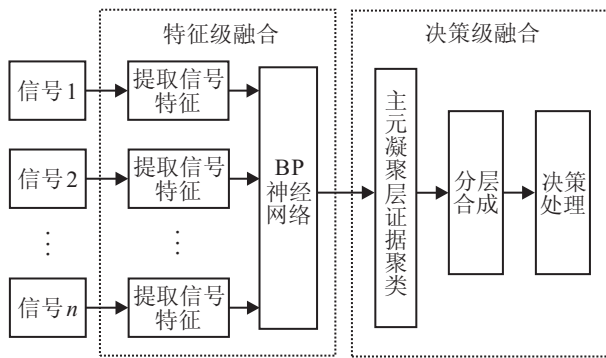


图2 基于分层DSmT多故障诊断的系统结构

分层DSmT融合思想的主要思路可概括为:在某些特殊情况下,可以根据某种规则将辨识框架中的元素分为多组;然后将原GBPA按照某种规则重新分配,近似得到新辨识子框架下的GBPA;最终的决策结果为分层融合后结果的并集.

根据主元凝聚层证据聚类方法,假设广义辨识框架 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$ 被分为两层,即

$$\begin{cases} \Theta_1 = \{\theta_1, \theta_2, \dots, \theta_k\}, k > 1; \\ \Theta_2 = \{\theta_{k+1}, \dots, \theta_n\}, k+1 < n. \end{cases}$$

在广义辨识框架 $\Theta$ 下有相互独立的2个证据,它们的GBPA分别为 $m_1$ 和 $m_2$ .应用分层DSmT时,先将两组证据的GBPA根据分层后的辨识子框架进行归一化处理,然后按照自由DSmT组合规则进行融合.归一化公式如下:

$$m_{11}(\theta_i) = \frac{m_1(\theta_i)}{\sum_{i=1}^k m_1(\theta_i)}, \quad (10)$$

其中 $m_{11}(\theta_i)$ 表示证据 $e_1$ 的GBPA在辨识框架 $\Theta_1$ 下的信度函数.

#### 4 仿真分析

为验证本文所提出算法的有效性和准确性,利用Matlab随机生成故障样本数据来进行仿真验证.每种故障数据由8个变量组成,系统各变量输出信号分别按下式定义:

$$\begin{cases} x_1 = 0.5768s_1 + 0.3766s_2 + e_1, \\ x_2 = 0.3972s_1 + 0.3045s_2 + e_2, \\ x_3 = 0.7382s_1^2 + 0.0566s_2 + e_3, \\ x_4 = 0.2312s_1^2 + 0.6778s_2 + e_4, \\ x_5 = 0.3832s_1 + 0.1678s_2^2 + e_5, \\ x_6 = 0.8291s_1 + 0.4099s_2^2 + e_6, \\ x_7 = 0.3374s_1s_2 + 0.7565s_1 + e_7, \\ x_8 = 0.6519s_1s_2 + 0.2070s_2 + e_8. \end{cases} \quad (11)$$

其中: $e_1 \sim e_8$ 分别是分布在区间 $[-0.1, 0.1]$ 上标准偏差为0.01的零均值白噪声变量;两个数据源 $s_1$ 和 $s_2$ 用来反映变量运行状态中的变化情况, $s_1$ 为系统生成的一系列随机数, $s_2$ 服从 $[-15, 1]$ 区间的正态分布.从以上定义可以看出,变量之间既有线性关系又有非线性关系,符合多故障变量间的复杂性、多样性以及耦合性.

#### 4.1 仿真实验 I

为了验证混合DSmT融合以及分层DSmT融合方法是否对复杂多故障诊断有效,预先设定发生的故障模式为故障 $F_1$ 、 $F_3$ 的耦合故障和故障 $F_2$ 同时发生.故障类型与系统变量的对应关系如表1所示.

表1 故障样本信息表

故障	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$
$F_1$	1	0	1	0	1	0	0	0
$F_2$	0	0	0	1	0	1	1	0
$F_3$	1	0	1	0	0	0	0	1

由表1可知,故障 $F_1$ 与故障 $F_3$ 之间有相同的变量,故障 $F_2$ 与故障 $F_1$ 、故障 $F_3$ 之间没有相同的变量.若3种故障同时发生,则按照多故障定义即可认为,故障 $F_1$ 与故障 $F_3$ 发生了耦合故障,故障 $F_2$ 与故障 $F_1$ 、故障 $F_3$ 的耦合故障之间发生了独立多故障.

首先利用Matlab根据式(11)随机生成750组3种不同故障( $F_1$ 、 $F_2$ 、 $F_3$ )数据,并根据故障样本信息表将数据作为训练数据输入BP神经网络中.其中,设置BP神经网络各层次神经元个数分别为8、9、3.网络最大迭代次数设为5000,训练目标设为 $10^{-4}$ .随后,将60组待辨识的故障数据输入到训练好的BP神经网络中,得到60组特征层初步诊断结果,即证据.将特征层诊断结果转为GBPA后,从中随机选取6组证据分别进行混合DSmT融合、分层DSmT融合.其中,利用BP神经网络所获取的6个随机特征层初步诊断结果如表2所示.

由表2可以看出,诊断结果与预设不一致.这是由于多故障系统“故障-征兆”对应关系复杂多样,只

表 2 特征层初步诊断结果

证据	$m(F_1)$	$m(F_2)$	$m(F_3)$
$e_1$	0.4903	0	0.5097
$e_2$	0	1	0
$e_3$	0.5069	0	0.4931
$e_4$	0	0.9501	0.0499
$e_5$	0.4782	0	0.5218
$e_6$	0.5158	0	0.4842

利用特征层信息融合进行故障诊断时,其诊断结果往往不精确,难以对多故障类型进行有效辨识.为此,需要将特征层初步诊断结果作为决策层信息融合的证据进行进一步的融合,进而实现多故障的诊断.

应用混合 DSMT 进行多故障诊断时,首先根据已有知识分析约束条件.由于预设的故障模式为故障  $F_1$ 、 $F_3$  的耦合故障和故障  $F_2$  同时发生,约束条件为  $F_1 \cap F_2 = \emptyset, F_2 \cap F_3 = \emptyset$ .在该约束条件下进行混合 DSMT 融合时,诊断结果如表 3 所示.

表 3 6 组证据混合 DSMT 诊断结果

多故障超幂集	$m$	多故障超幂集	$m$
$a_0 = \emptyset$	0	$a_{13} = F_2 \cup F_3$	0.0081
$a_3 = F_1 \cap F_3$	0.8593	$a_{14} = (F_2 \cap F_3) \cup F_1$	0.0217
$a_5 = F_3$	0.0227	$a_{16} = F_1 \cup F_3$	0.0006
$a_{11} = F_2$	0.0077	$a_{17} = F_1 \cup F_2$	0.0082
$a_{12} = (F_1 \cap F_3) \cup F_2$	0.0685	$a_{18} = F_1 \cup F_2 \cup F_3$	0.0032

由表 3 可以看出,  $a_3$  获得了远大于其他命题的 GBPA,由此可以判定:故障  $F_1$ 、 $F_3$  同时发生.但仿真实验预先设定的故障模式为故障  $F_1$ 、 $F_3$  的耦合故障和故障  $F_2$  同时发生.因此,在该情况下应用混合 DSMT 未能诊断出故障  $F_2$  发生,即不能判别故障  $F_1$ 、故障  $F_2$ 、故障  $F_3$  之间的关系(耦合或独立),没有得到准确的诊断结果.

应用分层 DSMT 进行多故障诊断时,首先将 6 组证据利用主元凝聚层聚类方法实现证据聚类,得到的聚类结果如图 3 所示,聚类结果局部效果如图 4 所示.




图 3 6 组证据聚类层次树




图 4 6 组证据聚类层次树局部效果图

由图 3 可知,6 组证据被分成 2 类,即 6 组证据表示的是两种独立故障.随后,广义辨识框架中的元素根据两类证据主元被分成 2 个广义辨识子框架.最后在每个广义辨识子框架下对相应证据进行分层 DSMT 融合,得到的融合结果如表 4 所示.

表 4 6 组证据分层 DSMT 诊断结果

辨识子框架	多故障超幂集	$m$	多故障超幂集	$m$
1	$a_0 = \emptyset$	0.0499	$a_1 = F_2$	0.9501
	$a_0 = \emptyset$	0	$a_3 = F_1$	0.1318
2	$a_1 = F_1 \cap F_3$	0.7145	$a_4 = F_1 \cup F_3$	0.0198
	$a_2 = F_3$	0.1339		

由表 4 可知,利用主元凝聚层证据聚类算法将广义辨识框架分成了  $\Theta_1 = \{F_2\}$  和  $\Theta_2 = \{F_1, F_3\}$  两部分.在表 4 的辨识子框架 1 中,融合后最大的 GBPA 为 0.9501,故可判定故障  $F_2$  发生.在表 4 的辨识子框架 2 中,融合后最大的 GBPA 为 0.7145,故可判定故障  $F_1$ 、 $F_3$  同时发生.综合表 4 的诊断结果,可得分层 DSMT 最终的诊断结果为:故障  $F_1$ 、 $F_3$  的耦合故障和故障  $F_2$  同时发生,且故障  $F_2$  与故障  $F_1$ 、故障  $F_3$  相互独立,与设定模式相同.

综上,由仿真实验 I 可知:基于分层 DSMT 的多故障诊断方法较混合 DSMT 方法更好,其可根据当前证据将独立故障和耦合故障从广义辨识框架中分离出来,进而准确有效地诊断出故障类型.

#### 4.2 仿真实验 II

在仿真实验 I 中只预设了 3 种故障类型,而为了突出分层 DSMT 可在一定程度上减少融合过程计算量的优点,仿真实验 II 将在仿真实验 I 的基础上增加 3 种故障,所预设的 6 种故障类型分别为  $F_1 \sim F_6$ .其中,故障  $F_1$ 、 $F_2$ 、 $F_3$  设置与仿真实验 I 一致,即发生的故障模式为:故障  $F_1$ 、 $F_3$  的耦合故障和故障  $F_2$  同时发生;此外,增设故障  $F_4$ 、 $F_5$ 、 $F_6$  的耦合故障也同时发生.即仿真实验 II 预设的故障模式为:故障  $F_1$ 、 $F_3$  的耦合故障,故障  $F_2$  和故障  $F_4$ 、 $F_5$ 、 $F_6$  的耦合故障同时发生.

同样,利用 Matlab 生成相应的训练数据和故障数据,通过 BP 神经网络获得相互独立的多组数据,从中选取 18 组证据进行主元凝聚层证据聚类,得到的

证据聚类结果如图 5 所示, 聚类结果局部效果如图 6 所示.




图 5 18 组证据聚类层次树




图 6 18 组证据聚类层次树局部效果图

由图 5 可知, 18 组证据被分成 3 类, 即 18 组证据表示 3 种独立故障. 随后, 广义辨识框架中的元素根据三类证据主元被分成了 3 个广义辨识子框架. 最后, 在每个广义辨识子框架下对相应证据进行分层 DSMT 融合, 得到的融合结果如表 5 所示.

表 5 18 组证据分层 DSMT 诊断结果

辨识子框架	多故障超幂集	$m$	多故障超幂集	$m$
1	$a_0 = \emptyset$	0.0499	$a_1 = F_2$	0.9501
	$a_0 = \emptyset$	0	$a_3 = F_1$	0.1318
2	$a_1 = F_1 \cap F_3$	0.7145	$a_4 = F_1 \cup F_3$	0.0198
	$a_2 = F_3$	0.1339		
3	$a_1 = F_4 \cap F_5 \cap F_6$	0.5465	$a_{10} = (F_4 \cup F_5) \cup F_6$	0.0000
	$a_2 = F_5 \cap F_6$	0.1334	$a_{11} = F_5$	0.0001
	$a_3 = F_4 \cap F_6$	0.1041	$a_{12} = (F_4 \cap F_6) \cup F_5$	0.0000
	$a_4 = (F_4 \cup F_5) \cap F_6$	0.0290	$a_{13} = F_5 \cup F_6$	0.0000
	$a_5 = F_6$	0.0000	$a_{14} = F_4$	0.0001
	$a_6 = F_4 \cap F_5$	0.1107	$a_{15} = (F_5 \cup F_6) \cup F_4$	0.0000
	$a_7 = (F_4 \cup F_6) \cap F_5$	0.0370	$a_{16} = F_4 \cup F_6$	0.0000
	$a_8 = (F_5 \cup F_6) \cap F_4$	0.0295	$a_{17} = F_4 \cup F_5$	0.0000
	$a_9 = (F_4 \cup F_5) \cup (F_4 \cap F_6) \cup (F_5 \cap F_6)$	0.0095	$a_{18} = F_4 \cup F_5 \cup F_6$	0.0000

由表 5 可以看出, 广义辨识框架被分成  $\Theta_1 = \{F_2\}$ 、 $\Theta_2 = \{F_1, F_3\}$  和  $\Theta_3 = \{F_4, F_5, F_6\}$  三部分. 广义辨识子框架  $\Theta_1$ 、 $\Theta_2$  下的融合结果与表 4 一致. 在广义辨识子框架  $\Theta_3$  下的融合结果中,  $a_1$  获得了最大的 GBPA, 故可判定故障  $F_4$ 、 $F_5$ 、 $F_6$  同时发生. 综上所述, 利用分层 DSMT 的最终故障诊断结果为: 故障  $F_1$ 、 $F_3$  的耦合故障, 故障  $F_2$  和故障  $F_4$ 、 $F_5$ 、 $F_6$  的耦合故障同时发生, 与设定的模式相同.

当广义辨识框架中的元素为 6 个时, 若采用传统 DSMT 规则进行融合时, 超幂集会包含 7828353 个命题. 而采用分层 DSMT 规则进行融合时, 分层后各子框架需要融合的元素最多为 3 个, 此时各超幂集空间最多只包含 19 个命题. 所以, 融合过程中各命题的计算复杂度降低, 从而也减少了融合过程的计算量. 本

例中, 在传统的 DSMT 框架下 Matlab 需要约 59.73 MB 的存储容量来存储融合过程产生的信息; 而在分层 DSMT 框架下 Matlab 只需要约  $2 \times 10^{-4}$  MB 的存储容量. 可见, 在一定程度上该方法也节约了融合过程所需的存储空间.

### 5 结 论

本文提出的基于分层 DSMT 的多故障诊断方法, 适用于广义辨识框架中既含有独立多故障又含有耦合故障的复杂多故障诊断. 应用分层 DSMT 前, 采用主元凝聚层证据聚类方法将广义辨识框架分层, 进而得到若干个广义辨识子框架. 其中, 同一子框架中的故障元素可能发生单故障或耦合故障, 不同子框架之间的故障元素可能发生独立多故障. 即实现了将独立故障和耦合故障从广义辨识框架中分离出来. 采用分

层DSmT进行融合时,可以使每一个广义辨识子框架中证据所支持的故障模式的GBPA重新分配达到最大,进而得到准确的诊断结果。此外,由于广义辨识框架被分层,从而减少了超幂集空间所包含的命题数,降低了融合过程中的计算量。最后,通过仿真实验验证了所提出方法在诊断多故障时的有效性和准确性。

### 参考文献(References)

- [1] Wang Z Y, Chen J, Dong G M, et al. Constrained independent component analysis and its application to machine fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2011, 25(7): 2501-2502.
- [2] Kugi A, Haas W, Schlacher K, et al. Active compensation of roll eccentricity in rolling mills[J]. *IEEE Trans on Industry Applications*, 2000, 36(2): 625-632.
- [3] Zhang X, Zhang D H, Cheng P W, et al. On quality control strategy in last stand of tandem cold rolling mill[C]. *Chinese Control Conf(CCC)*. Hefei, 2012: 7562-7564.
- [4] Peng P, Yang Q. Generalized shape and gauge decoupling load distribution optimization based on IGA for tandem cold mill[J]. *Int J of Iron and Steel Research*, 2009, 16(2): 30-34.
- [5] 张冀, 王兵树. 传感器多故障诊断的信息融合方法研究[J]. *中国电机工程学报*, 2007, 27(16): 104-108.  
(Zhang J, Wang B S. Research on information fusion for sensors multiple fault diagnosis[J]. *Proc of the CSEE*, 2007, 27(16): 104-108.)
- [6] 文成林, 徐晓斌. 多源不确定信息融合理论及应用[M]. 北京: 科学出版社, 2012: 128-130.  
(Wen C L, Xu X B. *Theories and applications in multi-source uncertain information fusion-Fault diagnosis and reliability evaluation*[M]. Beijing: Science Press, 2012: 128-130.)
- [7] Jiang H N, Xu X B, Wen C L. The combination method for dependent evidence and its application for simultaneous faults diagnosis[C]. *Int Conf on Wavelet Analysis and Pattern Recognition*. Baoding, 2009: 496-501.
- [8] Dezert J. Foundations for a new theory of plausible and paradoxical reasoning[J]. *Information and Security*, 2002, 9(1): 13-57.
- [9] Smarandache F, Dezert J. *Advances and applications of DSmT for information fusion*[M]. Rehoboth: American Research Press, 2004: 2-4.
- [10] 翟旭升, 胡金海, 谢寿生, 等. 基于DSmT的航空发动机早期振动故障融合诊断方法[J]. *航空动力学报*, 2012, 27(2): 301-306.  
(Zhai X S, Hu J H, Xie S S, et al. Diagnosis of aero-engine with early vibration fault symptom using DSmT[J]. *J of Aerospace Power*, 2012, 27(2): 301-306.)
- [11] Tessem B. Approximations for efficient computation in the theory of evidence[J]. *Artificial Intelligence*, 1993, 61(2): 315-329.
- [12] Denoeux T. Inner and outer approximation of belief structures using a hierarchical clustering approach[J]. *Int J of Uncertainty, Fuzziness and Knowledge-Based Systems*, 2001, 9(4): 437-460.
- [13] 李新德, Dezert J. 一种快速分层递阶DSmT近似推理融合方法[J]. *电子学报*, 2010, 38(11): 2566-2572.  
(Li D X, Dezert J. A fast approximate reasoning method in Hierarchical DSmT[J]. *Acta Electronica Sinica*, 2010, 38(11): 2566-2572.)
- [14] 沈怀荣, 杨露. 信息融合故障诊断技术[M]. 北京: 科学出版社, 2013: 217-222.  
(Shen H R, Yang L. *Information fusion fault diagnosis technology*[M]. Beijing: Science Press, 2013: 217-222.)
- [15] Jousselme A L, Dominic G, Bosse E. A new distance between two bodies of evidence[J]. *Information Fusion*, 2001, 2(2): 91-101.

(责任编辑: 李君玲)