

文章编号: 1000-8152(2011)04-0504-07

# 评估诊断证据可靠性的信息融合故障诊断方法

徐晓滨, 王玉成, 文成林

(杭州电子科技大学 自动化学院, 浙江 杭州 310018)

**摘要:** 在基于证据理论的信息融合故障诊断方法中, 诊断证据的可靠性高低将会直接影响诊断结果的准确性。而现有的大多数方法并没有全面地评估证据的可靠性, 从而常常导致融合诊断结果的不准确。决定证据可靠性的因素主要有传感器的精度与证据获取方法的性能, 以及传感器运行环境中的不确定性因素, 可将它们分别理解为静态和动态因素。本文利用基于Pignistic的指标函数优化算法获得静态折扣因子, 用其对原证据进行修正; 接着提出基于Pignistic向量的证据相似度度量方法获取动态折扣因子, 用其对证据进行再次修正, 并利用Dempster组合规则融合经两次修正后的证据, 得到诊断结果。最后, 通过在多功能柔性转子试验台上的实验, 验证了所提方法的有效性。

**关键词:** 故障诊断; 信息融合; 证据理论; 传感器可靠性; 折扣因子

中图分类号: TP391 文献标识码: A

## Information-fusion method for fault diagnosis based on reliability evaluation of evidence

XU Xiao-bin, WANG Yu-cheng, WEN Cheng-lin

(School of Automation, Hangzhou Dianzi University, Hangzhou Zhejiang 310018, China)

**Abstract:** In fault diagnosis methods based on evidence theory with information fusion, the reliabilities of evidences will affect the accuracy of diagnosis results. However, most existing fusion diagnosis methods do not take the reliabilities of the evidences into account comprehensively. The main factors which determine the reliability of evidence are the precision of individual sensor and the performance of the method in obtaining the evidence, as well as the uncertainties in the observation environment. They are considered static factors and dynamic factors. The original evidence is first modified by a static discount-factor obtained by optimizing the indication function of Pignistic probability measure. This result is further modified by a dynamic discount-factor which is obtained by applying the measurement method to evidence similarity in Pignistic vectors. Double-modified evidences are combined by Dempster combination rule to obtain the final diagnosis results. Experiments on the multi-functional flexible rotor-testing validate the effectiveness of the proposed method.

**Key words:** fault diagnosis; information fusion; evidence theory; sensor reliability; discounting factor

## 1 引言(Introduction)

在进行设备故障诊断时, 希望在不增加传感器个数的情况下获得尽可能多的诊断信息, 而利用先进的信息融合技术往往能满足这种需求<sup>[1]</sup>。由于证据理论可以有效地表示和处理信息的不确定、非精确性等, 在信息融合的故障诊断中得以广泛应用。但是, 融合诊断的效果高度依赖证据源的可靠性, 如果诊断证据不可靠, 不论采取何种融合规则, 都会造成诊断结果错误。在故障诊断中, 影响证据可靠性的因素主要有两方面: 一是静态因素, 即传感器自身精度与证据获取方法性能; 二是动态因素, 传感器运行环境中的不确定性因素干扰。其中任何这些不利因素的出现都会引起诊断证据的可靠性下降, 甚至造成

不同信息源所提供证据之间的冲突, 进而影响融合结果的正确性<sup>[2]</sup>。所以, 在证据融合之前, 用相应方法对证据进行预处理, 减少不可靠因素对融合效果的影响, 增加证据的客观性显得十分必要。然而, 到目前为止, 基于证据理论的故障诊断方法多数没有全面地考虑动、静态因素对证据可靠性的影响。

在证据理论中, Shafer引入了折扣因子来度量信息源的可靠性<sup>[3]</sup>, 并对信息源最后产生的证据按照折扣因子进行修正, 可靠性与折扣因子是相互联系的, 可靠性越小, 折扣因子越大。在Shafer的基础上, Z. Elouedi等人在文献[4]中提出了最小化误差函数的方法来计算折扣因子。在文献[5]中, L. M. Zouhal等人采用k-nearest neighborhood的方法, 即每

收稿日期: 2010-09-09; 收修改稿日期: 2010-11-04。

基金项目: 国家自然科学基金资助项目(61004070, 60934009, 60772006, 60874105); 浙江省自然科学基金资助项目(Y1080422); 中国博士后科学基金资助项目(20100470353)。

个观测集是知道的, 折扣因子依赖训练集数据与将被分类的新数据之间的距离来获得。在文献[6]中, Z. Elouedi等人又提出了最小化Pignistic概率距离的方法来计算折扣因子。但是这些方法都停留在静态可靠性折扣因子的求取上, 并没有考虑诸如故障诊断等应用环境中, 由于信息源(传感器)运行中影响证据可靠性的动态因素, 从而不能通过已有方法较全面地评价诊断证据的可靠性。

Smets提出的可转移信度模型(transferrable belief model, TBM)提供了灵活的建模方法, 处理多传感器信息融合中所遇到的不确定性问题及证据冲突问题。本文基于TBM中的Pignistic概率给出了度量诊断证据静态和动态可靠性的方法。本文首先利用基于Pignistic概率测度的指标函数优化算法求出静态折扣因子, 并用其对原始证据进行修正。该因子是对传感器先验可靠性的度量, 是在传感器投入使用之前通过离线训练得到的, 它与传感器的精度与证据获取方法的性能有关; 然后提出Pignistic余弦相似度方法获取证据的动态折扣因子, 用其对静态因子修正后的证据进行二次修正, 该因子用以度量在传感器投入使用后外界干扰对其可靠性的影响; 最后利用Dempster组合规则对修改后的证据进行融合得到诊断结果。通过在多功能柔性转子试验台上的实验, 表明了本文提出的方法可有效的评估证据的可靠性, 解决因为可靠性下降引起的证据冲突问题, 并得到正确的诊断结果。

## 2 证据理论基础(Theoretical aspects of evidence theory)

证据理论最初是由Dempster于20世纪60年代提出, 后经Shafer扩展而形成完整的D-S理论体系, 它用于处理不确定及非精确信息, 这里简单的介绍一些基本概念<sup>[3]</sup>。

设辨识框架 $\Theta$ 是一有限非空集合, 它包含了完备且相互独立的元素。 $\Theta$ 的所有子集组成的集合称为 $\Theta$ 的幂集, 记作 $2^\Theta$ 。

**定义1** 设函数 $m: 2^\Theta \rightarrow [0, 1]$ , 若其满足 $m(\emptyset) = 0$ ,  $\emptyset$ 表示空集, 则称 $m$ 为质量函数, 它也称作基本概率赋值(BPA)。 $m(A)$ 表示证据对 $A$ 的支持程度, 如果 $m(A) > 0$ , 那么 $A$ 叫做辨识框架 $\Theta$ 的焦元。某证据源提供的一组关于 $\Theta$ 的BPA称作一个证据(体)(Body of evidence), 通常可以简称为证据。

**定义2** 设 $m_1, m_2$ 是辨识框架 $\Theta$ 上两个质量函数, 用Dempster组合规则可以得到它们合并后的综合结果, 如下式:

$$m(A) = \begin{cases} \frac{\sum_{B \cap C = A} m_1(B)m_2(C)}{1 - k}, & A \neq \emptyset, \\ 0, & A = \emptyset. \end{cases} \quad (1)$$

其中:  $k = \sum_{B \cap C = \emptyset} m_1(B)m_2(C)$ 表示两条证据之间的冲突程度。

**定义3** 证据的可靠性反映了使用者对传感器读数的信任程度。若设定证据可靠性的折扣因子为 $\alpha$ , 则证据的可靠度就为 $1 - \alpha$ 。由该传感器测得的BPA可用下式进行修正<sup>[3, 7]</sup>

$$m^\alpha(A) = \begin{cases} (1 - \alpha)m(A), & \forall A \subseteq \Theta, A \neq \emptyset, \\ \alpha + (1 - \alpha)m(\emptyset), & A = \emptyset. \end{cases} \quad (2)$$

**定义4** 在可传递信度模型(TBM)中, 将从BPA转换成BetP概率函数的过程叫做Pignistic转换, 相应的BetP概率函数定义如下<sup>[8, 9]</sup>:

$$\text{Bet } P_m(\theta_i) = \sum_{A \subseteq \Theta, \theta_i \in A} \frac{1}{|A|} \frac{m(A)}{1 - m(\emptyset)}. \quad (3)$$

## 3 诊断证据可靠性折扣因子的计算(The calculation of the discounting factor of diagnosis evidence )

通常情况下, 决定诊断证据可靠性的因素主要有两个方面, 一是传感器自身品质的优劣以及证据获取方法性能的差异, 二是在传感器运行过程中受外界不确定性因素的干扰(如接触不良, 环境噪声等), 使得传感器所获信息不准确甚至导致错误。这两个方面的因素都会影响诊断证据的可靠性和准确性, 可将它们分别理解为静态和动态因素<sup>[9]</sup>。本节利用基于Pignistic的指标函数优化算法获得静态折扣因子 $\alpha^s$ , 并用其对原始证据进行修正; 接着提出基于Pignistic向量的证据相似度度量方法获取动态折扣因子 $\alpha^d$ , 并用其对证据进行再次修正, 从而获得待融合诊断证据。

### 3.1 静态折扣因子的计算(The calculation of the static discounting factor)

若设备的故障集为 $\Theta = \{\theta_1, \theta_2, \dots, \theta_p\}$ , 通过故障模拟试验信息, 可以获得某个传感器对故障集 $\Theta$ 中各个故障模式的监测数据, 即观测集 $O = \{o_1, o_2, \dots, o_n\}$ , 且 $n \gg p$ 。那么, 对于每一组观测 $o_j \in O$ , 笔者就能知道该观测是在何种故障模式 $c_j \in \Theta$ 下获得的, 可将由该组观测中获取的诊断证据记作 $m\{o_j\}$ 。

若传感器的静态折扣因子为 $\alpha^s$ , 则可利用式(2)获得折扣后的BPA, 记为 $m^{\alpha^s}\{o_j\}$ 。利用式(3)将 $m^{\alpha^s}\{o_j\}$ 转换成Pignistic概率函数, 表示成 $\text{Bet } P^{\alpha^s}\{o_j\}$ , 然后将其与事先设定的故障模式 $c_j$ 比较, 设指示函数 $\delta_{i,j}(j = 1, \dots, n, i = 1, \dots, p)$ , 当 $\theta_i = c_j$ 时,  $\delta_{i,j} = 1$ , 否则 $\delta_{i,j} = 0$ 。那么, 就可以定义 $\text{Bet } P^{\alpha^s}\{o_j\}$ 与指标函数 $\delta_{i,j}$ 之间的欧式距离为<sup>[2, 6]</sup>

$$\text{Dist}(o_j, \alpha^s) = \sum_{i=1}^p (\text{Bet } P^{\alpha^s}\{o_j\}(\theta_i) - \delta_{i,j})^2, \quad (4)$$

则 $n$ 组观测与 $\delta_{i,j}$ 之间的欧式距离为<sup>[6]</sup>

$$\begin{aligned} \text{TotalDist} &= \sum_{j=1}^n \text{Dist}(o_j, \alpha^s) = \\ &\sum_{j=1}^n \sum_{i=1}^p (\text{Bet} P^{\alpha^s} \{o_j\}(\theta_i) - \delta_{j,i})^2. \end{aligned} \quad (5)$$

可见, TotalDist是关于 $\alpha^s$ 的距离指标函数, 最小化TotalDist, 即可得到 $\alpha^s$ . 此时, 经 $\alpha^s$ 修正后得到的 $\text{Bet} P^{\alpha^s} \{o_j\}$ 表示在TotalDist最小的意义下, 使得 $\text{Bet} P^{\alpha^s} \{o_j\}$ 尽可能接近真实的指标函数 $\delta_{i,j}$ , 亦即 $m^{\alpha^s} \{o_j\}$ 中对各个故障命题的BPA分布尽可能的反映真实发生的故障.

以下本文给出用最小化TotalDist的方法来求解 $\alpha^s$ 的过程. 假定从某个传感器的第 $j$ 组观测中获得的BPA为 $m\{o_j\}$ , 则用静态折扣变量 $\alpha$ 对原证据修正后得到新证据

$$m^\alpha \{o_j\}(A) = \begin{cases} (1-\alpha)m\{o_j\}(A), & A \subset \Theta, \\ (1-\alpha)m\{o_j\}(\Theta) + \alpha, & A = \Theta. \end{cases} \quad (6)$$

$A$ 为焦元, 由式(3)求得原证据的Pignistic概率函数为

$$\text{Bet} P\{o_j\}(\theta_i) = \frac{\sum_{A:\theta_i \in A} m\{o_j\}(A)}{|A|}. \quad (7)$$

由式(6)(7)得

$$\begin{aligned} \text{Bet} P^\alpha \{o_j\}(\theta_i) &= \sum_{A:\theta_i \in A} \frac{m^\alpha \{o_j\}(A)}{|A|} = \\ &\sum_{A:\theta_i \in A} (1-\alpha) \frac{m\{o_j\}(A)}{|A|} + \frac{\alpha}{p} = \\ &(1-\alpha)\text{Bet} P\{o_j\}(\theta_i) + \frac{\alpha}{p}. \end{aligned} \quad (8)$$

其中 $p = |\Theta|$ . 令 $p_{ij} = \text{Bet} P\{o_j\}(\theta_i)$ , 则有

$$\begin{aligned} \text{TotalDist} &= \sum_{j=1}^n \sum_{i=1}^p (\text{Bet} P^\alpha \{o_j\}(\theta_i) - \delta_{j,i})^2 = \\ &\sum_{j=1}^n \sum_{i=1}^p ((1-\alpha)p_{ij} + \frac{\alpha}{p} - \delta_{j,i})^2. \end{aligned}$$

当 $\frac{d \text{TotalDist}(\alpha)}{d\alpha} = 0$ 时, 上式取到极值, 亦即

$$\begin{aligned} 0 &= \frac{d \text{TotalDist}(\alpha)}{d\alpha} = \\ &2 \sum_{j,i} ((1-\alpha)p_{ij} + \frac{\alpha}{p} - \delta_{j,i})(-p_{ij} + \frac{1}{p}) \propto \\ &\sum_{j,i} -(1-\alpha)p_{ij}^2 - \frac{\alpha n}{p} + \sum_{j,i} \delta_{j,i} p_{ij} + \\ &\frac{(1-\alpha)n}{p} + \frac{\alpha n}{p} - \frac{n}{p} = \\ &\sum_{j,i} -(1-\alpha)p_{ij}^2 - \frac{\alpha n}{p} + \sum_{j,i} \delta_{j,i} p_{ij}, \end{aligned}$$

求得 $\alpha = (\sum_{j,i} (\delta_{j,i} - p_{ij}) p_{ij}) / (n/p - \sum_{j,i} p_{ij}^2)$ . 为了保

证 $\alpha^s \in [0, 1]$ , 最终取

$$\alpha^s = \min(1, \max(0, \alpha)). \quad (9)$$

### 3.2 动态折扣因子的计算(The calculation of the dynamic discounting factor)

静态折扣因子可以被看作是用来评估传感器的先验可靠性, 是在该传感器投入使用之前通过离线训练得到的, 但并没有考虑其投入使用后受到的外界干扰引起的可靠性变化, 例如传感器接触不良, 环境噪声干扰等. 这些因素会引起传感器观测的不准确甚至错误, 最终导致该传感器提供的诊断证据和其他传感器的诊断证据之间出现冲突现象. 这些外界因素对证据可靠性的影响会动态地体现在传感器的每次观测当中. 若同时有 $N$ 个传感器对设备进行监测, 在假定有一个传感器因外界干扰而可靠性下降的情况下, 本节建立Pignistic证据相似度空间, 通过Pignistic转换将诊断证据转化为该空间中的证据向量. 利用证据向量的夹角余弦值度量各个传感器诊断证据之间的相似性, 并构造两两证据之间的相似度矩阵, 从中获取证据的动态折扣因子 $\alpha^d$ , 用其对静态因子修正后的证据进行二次修正, 进一步度量外界干扰对传感器获取的诊断证据可靠性的影响.

**定义5** 相似度函数. 设 $A, B$ 为 $\mathbb{R}^n$ 空间中任意两向量, 函数 $S(A, B) : A @ B \rightarrow [0, 1]$ 称为相似度函数, 如果它满足: 1)  $0 \leq S(A, B) \leq 1$ ; 2)  $S(A, B) = S(B, A)$ ; 3)  $S(A, B) = 1$ 当且仅当 $A = B$ ;  $S(A, B) = 0$ 当且仅当 $A \perp B$ .

**定义6** 相似度空间在集合 $P$ 上定义一个二元实值函数 $S(x, y)$ , 如果对任意的 $x, y \in P$ ,  $S(x, y)$ 满足定义5中的3个基本条件, 则称 $P$ 为相似度空间.

将从第 $k$ 个传感器中获得的证据记为 $m_k$ ,  $k = 1, 2, \dots, N$ , 其中 $N$ 是传感器的个数, 并且它们是相互独立的, 那么可以利用式(3)将证据中各个焦元的mass函数转化为 $\Theta$ 中单个元素的Pignistic概率 $\text{Bet} P_{m_k}(\theta_i)$ . 若以每个元素的 $\text{Bet} P_{m_k}(\theta_i)$ 为坐标建立一个 $\mathbb{R}^p$ 维的空间( $p$ 代表 $\Theta$ 中元素个数), 则可以定义在此空间中的一组Pignistic证据向量 $\overrightarrow{\text{Bet} P_{m_k}}$ , 其中的每一个分量代表辨识框架 $\Theta$ 中相应元素的Pignistic概率取值, 所有传感器提供的诊断证据组成一个含有 $N$ 个Pignistic证据向量的集合. 由于该空间满足定义5和定义6, 所以称此空间为Pignistic证据相似度空间.

进一步定义Pignistic证据向量的余弦相似度为

$$\begin{aligned} \text{Sim}(\overrightarrow{\text{Bet} P_{m_k}}, \overrightarrow{\text{Bet} P_{m_q}}) &= \cos \varphi = \\ &\frac{\overrightarrow{\text{Bet} P_{m_k}} \cdot \overrightarrow{\text{Bet} P_{m_q}}^T}{\|\overrightarrow{\text{Bet} P_{m_k}}\| \|\overrightarrow{\text{Bet} P_{m_q}}\|}, \end{aligned} \quad (10)$$

其中  $\overrightarrow{\text{Bet}P_{m_k}} \cdot \overrightarrow{\text{Bet}P_{m_q}}^T = \sum_{i=1}^p \overrightarrow{\text{Bet}P_{m_{k,i}}} \cdot \overrightarrow{\text{Bet}P_{m_{q,i}}}$ ,  $i = 1, 2, \dots, p$ ,  $p$  是向量维数(即辨识框架中元素个数).  $\|\cdot\|$  表示向量的范数, 上式实际上表示向量  $\overrightarrow{\text{Bet}P_{m_k}}$  与  $\overrightarrow{\text{Bet}P_{m_q}}$  夹角的余弦度量, 若  $\overrightarrow{\text{Bet}P_{m_k}}$  与  $\overrightarrow{\text{Bet}P_{m_q}}$  的夹角  $\varphi = 0^\circ$ , 则其相似度为1, 并且说明  $\overrightarrow{\text{Bet}P_{m_k}}$  和  $\overrightarrow{\text{Bet}P_{m_q}}$  对  $\Theta$  中每个元素的支持度相同. 若  $\overrightarrow{\text{Bet}P_{m_k}}$  与  $\overrightarrow{\text{Bet}P_{m_q}}$  的夹角  $\varphi = 90^\circ$ , 则其相似度为0, 即两证据完全冲突.

对含有  $N$  个传感器的融合系统中, 由式(3)得到证据向量  $\overrightarrow{\text{Bet}P_{m_k}}$  与  $\overrightarrow{\text{Bet}P_{m_q}}$ . 由式(10)计算得相似度矩阵

$$\text{SMM} = \begin{bmatrix} S_{11} & S_{12} & \cdots & S_{1N} \\ S_{21} & S_{22} & \cdots & S_{2N} \\ \vdots & & & \vdots \\ S_{N1} & S_{N2} & \cdots & S_{NN} \end{bmatrix}.$$

对于证据  $k$  的总支持度为

$$\text{Sup}(m_k) = \sum_{\substack{k=1 \\ k \neq q}}^N \text{SMM}(\overrightarrow{\text{Bet}P_{m_k}}, \overrightarrow{\text{Bet}P_{m_q}}). \quad (11)$$

一般来说, 一个证据被其他证据所支持的程度越高, 则说明这个证据越可靠. 反之亦然. 直观地, 传感器的相对置信度为

$$\text{Rcrd}(k) = \frac{\text{Sup}(m_k)}{\sum_{k=1}^N \text{Sup}(m_k)}. \quad (12)$$

**定义 7** 对于  $N$  个传感器, 把具有较高的相对置信度的传感器看作是主传感器, 其他的都看作是次要传感器. 假设把次要传感器的相对置信度以一定的比例分配到主传感器中, 没有其他的信息变化, 则主传感器的绝对可靠性等于1, 其他传感器的可靠性为  $\beta_i^{[10,11]}$ .

$$\text{Acrd}(k) = \frac{\text{Rcrd}(k)}{\max_{k=1, \dots, N} \text{Rcrd}(k)}. \quad (13)$$

根据前面所介绍的置信度与折扣因子之间的关系, 笔者定义第  $k$  个传感器所获诊断证据的动态折扣因子为

$$\alpha_k^d(k) = 1 - \text{Acrd}(k). \quad (14)$$

若经静态因子  $\alpha^s$  修正后的证据为  $m_k^{\alpha^s}$ ,  $k = 1, 2, \dots, N$ , 则每个证据的动态因子  $\alpha^d$  是在该证据基础上得到的, 经动、静态折扣因子两次修正后的证据为

$$m_k^{\alpha^s, d}(A) = \begin{cases} (1-\alpha_k^d)m_k^{\alpha^s}(A), & A \subset \Theta, \\ (1-\alpha_k^d)m_k^{\alpha^s}(\Theta) + \alpha_k^d, & A = \Theta. \end{cases} \quad (15)$$

然后, 就可以用式(1)对上式中得到的  $k$  个证据进行

融合, 得到最终的融合诊断结果.

#### 4 决策准则(Decision criteria)

在基于证据推理的故障决策中, 要利用融合结果BPA对设备出现的故障做出判断, 就需要一定的判定准则<sup>[12]</sup>. 这里给出故障决策的基本准则如下:

1) 在进行设备故障诊断时, 判定的故障类型应有最大的BPA, 且该值要大于某一门限, 一般取门限为0.6, 亦即所判定故障发生的可能性要大于确定性概率100%的一半;

2) 不确定度要小于某一门限, 一般取门限为0.3, 命题“ $\Theta$ ”表示不知道何种故障发生, 因为融合的目的是要减小决策时的不确定性, 若对该命题的赋值过大, 将使结论含糊无法准确给出决策;

3) 判定某种故障的BPA与其他故障的BPA之差要大于某一门限, 一般取门限不小于0.15, 该值的确定是考虑到决策时要注意不同故障命题信度之间的差异, 只有它们之间的信度差达到一定的程度才能给出确定性的判断.

#### 5 实例分析(Analysis of examples)

笔者以“转子故障诊断模拟系统”为对象, 验证本文所述方法的有效性. 首先, 在实验台上分别设置  $F_0 = \{\text{正常运行}\}$ ,  $F_1 = \{\text{不平衡}\}$ ,  $F_2 = \{\text{不对中}\}$  和  $F_3 = \{\text{基座松动}\}$  4种典型故障模式, 利用加速度( $S_1$ )、速度( $S_2$ )、位移( $S_3$ )3种传感器采集转子时域振动均值作为观测信号. 经HG-8902数据采集系统将信息上传至计算机, 然后应用Labview环境下的HG-8902数据分析软件记录每个振动信号. 利用文献[13]的方法获得3种传感器下的诊断证据, 亦即BPA.

##### 5.1 求静态折扣因子(Calculate the static discounting factor)

设故障模式集  $\Theta = \{F_0, F_1, F_2, F_3\}$ . 通过故障模拟实验, 获得3种传感器在4种故障模式下分别获取的30组观测, 共可以求取出360组诊断证据作为计算静态折扣因子时的样本. 由于篇幅限制, 表1~3中分别只列出了  $S_1 \sim S_3$  在  $F_0 \sim F_3$  情况下的4组样本.

基于  $S_1$  在  $F_0 \sim F_3$  情况下的120组诊断证据样本, 由式(5)可得

$$\text{TotalDist} = \alpha_1^2 - 0.23\alpha_1 + 5.22. \quad (16)$$

最小化式(16)得

$$\alpha_1 = 0.1150,$$

由式(9)得  $\alpha_1^s = 0.1150$ . 同理, 对于  $S_2$  和  $S_3$  可求得

$$\alpha_2^s = 0, \alpha_3^s = 0.2785.$$

由静态折扣因子可以看出传感器  $S_2$  比传感器  $S_1$ ,  $S_3$  可靠.

表1  $S_1$ 在 $F_0 \sim F_3$ 情况下的4组诊断证据样本Table 1 4 sets of  $S_1$  diagnosis evidence samples when  $F_0 \sim F_3$  happen respectively

故障模式	$F_0$	$F_1$	$F_2$	$F_3$
$m(F_0)$	0.50 0.42 0.39 0.35	0.25 0.22 0.21 0.20	0.18 0.18 0.18 0.17	0.17 0.17 0.17 0.17
$m(F_1)$	0.40 0.54 0.59 0.54	0.39 0.33 0.30 0.28	0.25 0.24 0.23 0.22	0.22 0.21 0.21 0.21
$m(F_2)$	0.00 0.00 0.02 0.10	0.26 0.29 0.31 0.32	0.33 0.32 0.32 0.32	0.31 0.30 0.31 0.30
$m(F_3)$	0.00 0.00 0.00 0.01	0.06 0.11 0.14 0.18	0.24 0.26 0.27 0.29	0.30 0.31 0.31 0.32
$m(\Theta)$	0.10 0.04 0.00 0.00	0.04 0.05 0.04 0.02	0.00 0.00 0.00 0.00	0.00 0.01 0.00 0.00

表2  $S_2$ 在 $F_0 \sim F_3$ 情况下的4组诊断证据样本Table 2 4 sets of  $S_2$  diagnosis evidence samples when  $F_0 \sim F_3$  happen respectively

故障模式	$F_0$	$F_1$	$F_2$	$F_3$
$m(F_0)$	1.00 1.00 1.00 0.62	0.16 0.12 0.10 0.08	0.07 0.07 0.06 0.07	0.07 0.07 0.07 0.07
$m(F_1)$	0.00 0.00 0.00 0.00	0.50 0.48 0.42 0.36	0.29 0.27 0.26 0.25	0.23 0.22 0.22 0.21
$m(F_2)$	0.00 0.00 0.00 0.00	0.25 0.30 0.32 0.32	0.33 0.33 0.34 0.33	0.34 0.34 0.33 0.33
$m(F_3)$	0.00 0.00 0.00 0.00	0.03 0.09 0.16 0.23	0.30 0.33 0.34 0.35	0.35 0.35 0.35 0.34
$m(\Theta)$	0.00 0.00 0.00 0.38	0.06 0.01 0.00 0.01	0.01 0.00 0.00 0.00	0.01 0.02 0.03 0.05

表3  $S_3$ 在 $F_0 \sim F_3$ 情况下的4组诊断证据样本Table 3 4 sets of  $S_3$  diagnosis evidence samples when  $F_0 \sim F_3$  happen respectively

故障模式	$F_0$	$F_1$	$F_2$	$F_3$
$m(F_0)$	0.49 0.37 0.28 0.22	0.17 0.16 0.15 0.14	0.12 0.11 0.11 0.11	0.11 0.11 0.11 0.11
$m(F_1)$	0.41 0.48 0.46 0.42	0.38 0.34 0.30 0.27	0.22 0.20 0.18 0.18	0.17 0.16 0.16 0.16
$m(F_2)$	0.03 0.13 0.26 0.36	0.42 0.43 0.42 0.40	0.38 0.36 0.35 0.34	0.33 0.33 0.32 0.31
$m(F_3)$	0.00 0.00 0.00 0.00	0.03 0.07 0.13 0.19	0.28 0.32 0.34 0.36	0.39 0.40 0.41 0.42
$m(\Theta)$	0.07 0.02 0.00 0.00	0.00 0.00 0.00 0.00	0.00 0.01 0.02 0.010	0.00 0.00 0.00 0.00

## 5.2 求动态折扣因子(Calculate the dynamic discounting factor)

实验中使用是压电式振动传感器, 其与转子平台之间用磁座连接, 通过传感器上的螺丝可以将其固定在磁座上. 为了模拟外界因素的干扰, 这里笔者通过拧松位移传感器 $S_3$ 螺丝的方式模拟由于长期使用或人为干扰造成的“接触不良”. 并且在设定转子处于不平衡运转状态为例, 由 $S_1$ ,  $S_2$ 和 $S_3$ 3种传感器采集转子的时域振动均值信号. 利用文献[13]的方法获得3种传感器下的原始的诊断证据如表4所示. 将表4中的3个诊断证据分别用静态折扣因子 $\alpha_1^s, \alpha_2^s, \alpha_3^s$ 修正后得到的修正后的证据

如表5所示.

从表5可以看出, 由于传感器 $S_3$ 出现了“接触不良”的异常现象, 从而导致其提供的证据和 $S_1$ ,  $S_2$ 提供的证据存在冲突. 求解它们的动态折扣因子, 由式(10)~(12)计算得

$$\text{Rcre}(S_1) = 0.3671, \text{Rcre}(S_2) = 0.3814,$$

$$\text{Rcre}(S_3) = 0.2515.$$

由式(13)(14)计算得

$$\alpha^d(S_1) = 0.0475, \alpha^d(S_2) = 0, \alpha^d(S_3) = 0.2645.$$

用以上动态折扣因子分别对表5中的证据进行修正, 可以得到待融合的诊断证据如表6所示.

表4  $S_1 \sim S_3$ 在 $F_1$ 情况下的原始诊断证据Table 4 The original diagnosis evidence of  $S_1 \sim S_3$  when  $F_1$  happens

故障模式	传感器	基本概率赋值				
		$m(F_0)$	$m(F_1)$	$m(F_2)$	$m(F_3)$	$m(\Theta)$
转子	$S_1$ (正常)	0.0085	0.7017	0.1547	0.0325	0.1026
不平衡	$S_2$ (正常)	0.1496	0.4534	0.1050	0.0340	0.2570
$F_1$	$S_3$ (异常)	0.0400	0.0520	0.8062	0.0018	0.1000

表 5  $S_1 \sim S_3$  在  $F_1$  情况下经静态折扣因子修正后的证据Table 5 The evidence revised by the static discounting factor of  $S_1 \sim S_3$  when  $F_1$  happens

故障模式	传感器	基本概率赋值				
		$m^{\alpha^s}(F_0)$	$m^{\alpha^s}(F_1)$	$m^{\alpha^s}(F_2)$	$m^{\alpha^s}(F_3)$	$m^{\alpha^s}(\Theta)$
转子	$S_1$ (正常)	0.0075	0.6210	0.1369	0.0288	0.2058
不平衡	$S_2$ (正常)	0.1496	0.4534	0.1050	0.0340	0.2570
$F_1$	$S_3$ (异常)	0.0289	0.0375	0.5817	0.0013	0.3506

表 6  $S_1 \sim S_3$  在  $F_1$  情况下经动态折扣因子修正后的证据Table 6 The evidence revised by the dynamic discounting factor of  $S_1 \sim S_3$  when  $F_1$  happens

故障模式	传感器	基本概率赋值				
		$m^{\alpha^{s,d}}(F_0)$	$m^{\alpha^{s,d}}(F_1)$	$m^{\alpha^{s,d}}(F_2)$	$m^{\alpha^{s,d}}(F_3)$	$m^{\alpha^{s,d}}(\Theta)$
转子	$S_1$ (正常)	0.0072	0.5975	0.1317	0.0278	0.2358
不平衡	$S_2$ (正常)	0.1496	0.4534	0.1050	0.0340	0.2570
$F_1$	$S_3$ (异常)	0.0190	0.0247	0.3834	0.0000	0.5719

### 5.3 融合诊断结果(The fusion diagnosis results)

表7中列出了3个原始诊断证据、对原始诊断证据直接融合、本文融合方法以及基于文献[2]中动态折扣因子求取方法的6种诊断结果。从表中可以看出,  $S_1$ ,  $S_2$ 和 $S_3$ 3个传感器都不能单独给出正确的诊断结果。由于 $S_3$ 异常所导致的证据冲突, 也使得直接用Dempster组合规则融合原证据后诊断结论的不确定。而对原证据进行静态折扣因子修正

后, 再用本文和文献[2]中求取动态折扣因子的方法修正原始证据然后融合, 根据决策准则就可以正确地判断出故障, 并且本文结果要优于基于文献[2]中方法的结果, 从而消除了由于传感器可靠性不佳所带来的诊断结果错误。需要指出的是, 当传感器及其所提供的证据的可靠性较高时, 对应的静动态折扣因子就很小, 这时就退化为直接融合的方法, 但同样可以得到正确的融合诊断结果。

表 7 3种诊断方法的结果比较

Table 7 The comparison of diagnosis results of 3 methods

故障模式	信息源	基本概率赋值					诊断结果
		$F_0$	$F_1$	$F_2$	$F_3$	$\Theta$	
转子 不平衡 $F_1$	$S_1$ (正常)	0.0085	0.7017	0.1547	0.0325	0.1026	不平衡
	$S_2$ (正常)	0.1496	0.4543	0.1050	0.0341	0.2570	不确定
	$S_3$ (异常)	0.0400	0.0520	0.8062	0.0018	0.1000	不对中
	直接融合	0.0212	0.4852	0.4705	0.0079	0.0152	不确定
	邓的距离方法	0.0500	0.6477	0.2113	0.0189	0.0721	不平衡
	本文方法	0.0495	0.6658	0.1930	0.0149	0.0723	不平衡

### 6 结论(Conclusion)

基于证据理论的信息融合故障诊断方法通过融合各个传感器提供的证据进行决策分析, 而待融合证据的可靠性将会直接影响诊断结果的准确性。现有的大多数融合诊断方法中并没有全面地考虑证据的可靠性, 从而常常导致融合诊断结果的不准确。本文在分析影响证据动静态可靠性因素的基础上, 基于Pignistic概率测度的指标函数

分类优化算法求出静态折扣因子, 并用该因子对原始证据进行修正。对修正后的诊断证据又用余弦相似度方法获取证据的动态折扣因子 $\alpha^d$ , 用其对静态因子修正后的证据进行二次修正。然后利用Dempster组合规则对修改后的证据进行融合得到诊断结果。通过在多功能柔性转子试验台上的实验, 表明了本文所提方法的有效性, 并对冲突证据进行处理, 从而提高设备故障诊断的精度。

## 参考文献(References):

- [1] 藤召胜, 罗隆福, 童调生. 智能检测系统与信息融合[M]. 北京: 机械工业出版社, 2000.  
(TENG Zhaosheng, LUO Longfu, TONG Tiaosheng. *Intelligent Detection System and Information Fusion*[M]. Beijing: China Machine Press, 2000.)
- [2] GUO H W, SHI W K, DENG Y. Evaluating sensor reliability in classification problems based on evidence theory[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 2006, 36(5): 970 – 981 .
- [3] SHAFER G. *A Mathematical Theory of Evidence*[M]. Princeton: Princeton University Press, 1976.
- [4] ELOUEDI Z, MELLOULI K, SMETS P. The evaluation of sensors' reliability and their tuning for multisensor data fusion within the transferable belief model[C] //Proceedings of the Sixth European Conference on Symbolic and Quantitative Approaches to Reasoning with Uncertainty. New York: Springer, 2001: 350 – 361.
- [5] ZOUHAL L M, DENOEUX T. An evidence theoretic  $k$ -nn rule with parameter optimization[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, 1998, 28(2): 263 – 271.
- [6] ELOUEDI Z, MELLOULI K, SMETS P. Assessing sensor reliability for multi-sensor data fusion within the transferable belief model[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 2004, 34(1): 782 – 787.
- [7] SMETS P. Belief functions: the disjunctive rule of combination and the generalized Bayesian theorem[J]. *International Journal of Approximate Reasoning*, 1993, 9(1): 1 – 35.
- [8] SMETS P. Decision making in the TBM: the necessity of the pignistic transformation[J]. *International Journal of Approximate Reasoning*, 2005, 38(2): 133 – 147.
- [9] SMETS P, KENNES R. The transferable belief model[J]. *International Journal of Artificial Intelligence*, 1994, 66(2): 191 – 243.
- [10] LIU Y, GAO X G, LU G S, et al. Multisensor target recognition based on the weighted evidence combination[J]. *Systems Engineering and Electronics*, 2003, 25(12): 1476 – 1477.
- [11] YAGER R R. On considerations of credibility of evidence[J]. *International Journal of Approximate Reasoning*, 1992, 7(2): 45 – 72.
- [12] 朱大奇, 刘永安. 故障诊断的信息融合方法[J]. 控制与决策, 2007, 22(12): 1321 – 1328.  
(ZHU Daqi, LIU Yong'an. Information fusion method for fault diagnosis[J]. *Control and Decision*, 2007, 22(12): 1321 – 1328.)
- [13] 徐晓滨, 文成林, 王迎昌. 基于模糊故障特征信息的随机集度量信息融合故障诊断方法[J]. 电子与信息学报, 2009, 31(7): 1635 – 1640.  
(XU Xiaobing, WEN Chenglin, WANG Yingchang. Information fusion algorithm of fault diagnosis based on random set metrics of fuzzy fault features[J]. *Journal of Electronics & Information Technology*, 2009, 31(7): 1635 – 1640.)
- [14] FABRE S, APPRIOU A, BRIOTTET X. Presentation and description of two classification methods using data fusion based on sensor management[J]. *Information Fusion*, 2001, 2(1): 49 – 71.
- [15] SMETS P. The application of the transferable belief model to diagnostic problems[J]. *International Journal of Intelligent Systems*, 1998, 13(2): 127 – 158.

## 作者简介:

**徐晓滨** (1980—), 男, 讲师, 在清华大学自动化系作博士后研究工作, 研究方向为不确定性信息处理、智能故障诊断, E-mail: xuxiaobin1980@163.com;

**王玉成** (1982—), 男, 杭州电子科技大学自动化学院, 控制理论与控制工程专业, 研究方向为信息融合与信息处理, E-mail: wangyucheng115@163.com;

**文成林** (1963—), 男, 教授, 博士生导师, 主要研究方向为多源同步和异步信息的多尺度建模理论与多尺度数据融合技术、随机集理论、动态系统的安全检测、监控与故障诊断技术, E-mail: wencl@hdu.edu.cn.