

基于证据推理规则的信息融合故障诊断方法

徐晓滨^{1†}, 郑进¹, 徐冬玲², 杨剑波²

(1. 杭州电子科技大学 自动化学院系统科学与控制工程研究所, 浙江 杭州 310018;

2. 曼彻斯特大学 决策与认知科学研究中心, 英国 曼彻斯特 M15 6PB)

摘要: 本文针对不确定性故障特征信息的融合决策问题, 给出基于证据推理 (evidence reasoning, ER) 规则的故障诊断方法. 首先基于故障特征样本似然函数归一化的方法求取各传感器 (信息源) 提供的诊断证据; 从传感器误差以及故障特征对各故障类型辨别能力的差异出发, 给出获取诊断证据可靠性因子的方法; 给出双目标优化模型训练得到诊断证据的重要性权重, 最后利用 ER 规则融合经可靠性因子和重要性权重修正后的诊断证据, 利用融合结果进行故障决策. 该方法继承了 Dempster-Shafer 证据理论处理不确定性信息融合问题的优点, 同时克服了它在实际应用中无法区分证据可靠性和重要性的不足, 使得所获诊断证据更为客观、可信. 最后, 通过在多功能电机转子试验台上的故障诊断实验, 验证了所提方法的有效性.

关键词: 故障诊断; 信息融合; 证据推理规则; 证据可靠性; 证据重要性

中图分类号: TP391 文献标识码: A

Information Fusion Method for Fault Diagnosis Based On Evidential Reasoning Rule

Xu Xiaobin^{1†}, Zheng Jin¹, Xu Dong-Ling², Yang Jian-Bo²

(1. Institute of System Science and Control Engineering, School of Automation, Hangzhou Dianzi University, Hangzhou Zhejiang 310018, China;

2. Decision and Cognitive Sciences Research Centre, The University of Manchester, Manchester M15 6PB, United Kingdom)

Abstract: This paper presents an Evidential Reasoning (ER)-based method of fault diagnosis by combining uncertain information of various fault features collected from multiple sources for fault decision-making. A normalization approach is applied to acquire diagnosis evidence from the likelihood function of fault feature samples gathered from information sources (sensors). A novel method is proposed to calculate evidence reliability according to sensor accuracy specifications and the differences of capabilities in recognizing fault modes through different fault features. A bi-objective optimization model is presented to train evidence weights to reflect the relative importance of evidence. The ER rule is then applied to combine multiple pieces of diagnosis evidence, which are regulated by their weights and reliability factors, and fault decision-making can thus be conducted on the basis of the combined results. The proposed ER-based fault diagnosis method inherits the main features of Dempster-Shafer evidence theory in uncertainty modelling, while providing a systematic process for explicitly taking into account the reliability and importance of evidence, thereby enabling rigorous inference and robust decision making. Finally, a diagnosis experiment on a rotor test bed is conducted to show the effectiveness of the proposed ER-based fault diagnosis method.

Key words: fault diagnosis; information fusion; evidence reasoning (ER) rule; evidence reliability; evidence importance

1 引言(Introduction)

在线故障监测与诊断是提高设备运行安全性和可靠性的有效途径, 其依赖各种传感器采集的故障特征(征兆)信号监测设备的运行状况. 通常, 同一故障可由多种不同的故障特征表征, 反之, 同一故障特征的变化可由不同故障所引起^[1]. 所以, 单一传感器一般

不能提供充足的故障信息用于诊断, 往往需要将多传感器提供的故障特征信息进行融合来实现精确诊断. 此外, 由于传感器误差、环境噪声干扰以及设备运行状况的变化等内因和外因的影响, 从传感器获取的故障特征往往是不确定、非精确甚至是不完整的. 面对此类多源不确定性信息融合问题, 基

收稿日期: 2015-03-27; 收修改稿日期: xxxx-xx-xx.

†通信作者. E-mail: xuxiaobin1980@163.com; Tel.: 13777598844.

基金项目: 欧洲委员会资助 The European Commission under the grant(EC-GPF-314836); 国家自然科学基金项目 The National Natural Science Foundation of China (61374123; 61433001); 重庆市高等学校优秀人才支持计划 Program for Excellent Talents of Chongqing Higher School(2014-18).

于Dempster-Shafer(DS)证据理论的信息融合方法,通过信度分布(诊断证据)来描述故障特征对各种故障模式(命题)的支持程度,利用Dempster组合规则融合多源诊断证据,从而可获得更为精确的融合结果,并用其进行故障决策^[2-5]. DS证据理论中还给出了证据折扣方法,通过设置证据折扣因子来描述传感器或其提供证据的可靠性或重要性^[6-7]. 但是证据的可靠性和重要性具有不同的物理意义,而已有的折扣方法并未将两个概念加以区分^[8]. 此外,折扣证据所得到的剩余信度被赋给“完全未知”,亦即整个辨识框架(所讨论命题的全集),这人为增加了单个证据的非精确性,并从本质上改变了原有证据的概率特征,亦即特异性(Specificity),从而导致经Dempster规则融合得到的证据的非精确性不仅人为地放大了并且失真了. 更为严重的是上述折扣因子方法使得Dempster规则失去了其“严格概率推理过程”的本质特性,因此不能作为贝叶斯(Bayes)规则在所讨论命题的幂集空间的严格扩展^[8].

新近发现的证据推理(ER)规则,已经成功应用于各个领域^[9-12],它明确地区分了证据可靠性和重要性的概念,此外,基于正交和定理给出的ER规则,是一个严格的概率推理过程,在每个证据都完全可靠的情况下,Dempster规则成为它的一种特殊情况^[8]. 文献[13]中进一步给出了基于数据统计和似然函数归一化的证据生成方法,不同于基于模糊匹配、神经网络等人工智能的证据提取方法^[1-4],它不需要对故障特征变化规律以及特征与故障模式之间的映射关系做出任何假设,是基于样本统计的数据驱动证据生成方法. 本文针对多源不确定性故障特征信息融合决策问题,给出基于ER规则的故障诊断方法. 首先基于故障特征样本似然函数归一化的方法求取各传感器(信息源)的诊断证据;从传感器误差以及故障特征对各故障类型辨别能力的差异出发,给出获取诊断证据可靠性因子的方法;给出双目标优化模型训练得到诊断证据的重要性权重,最后利用ER融合规则融合经可靠性因子和重要性权重修正后的诊断证据,利用融合结果进行故障决策. 该方法继承了Dempster-Shafer证据理论处理不确定性信息融合问题的优点,同时克服了它在实际应用中无法区分证据可靠性和重要性的不足;该方法中诊断证据的融合是一种概率推理过程,从而使得诊断过程不仅严格而且客观、可信. 最后,通过在多功能电机转子试验台上的故障诊断实验,验证了所提方法的有效性.

2 证据推理(ER)规则(Evidential Reasoning (ER) Rule)

令 $\Theta = \{h_1, h_2, \dots, h_N\}$ 是由 N 个两两互斥的假设构成的集合,它包含了所有可能的命题或假设,称该

集合为辨识框架. 由 Θ 及其所有子集组成的集类称为幂集,记作 $P(\Theta)$ 或 2^Θ . 一条证据可表示为(1)式所示的信度分布

$$e_j = \{(\theta, p_{\theta,j}) | \forall \theta \subseteq \Theta, \sum_{\theta \subseteq \Theta} p_{\theta,j} = 1\} \quad (1)$$

其中 $(\theta, p_{\theta,j})$ 是证据 e_j 的元素,表示 e_j 支持命题 θ 的程度为 $p_{\theta,j}$,此时, $p_{\theta,j}$ 即定义为信度函数或信度分布,这里 θ 可取 $P(\Theta)$ 中除了空集之外的任一元素,若有 $p_{\theta,j} > 0$,则称 $(\theta, p_{\theta,j})$ 是 e_j 的焦点.

在ER规则中,定义了证据 e_j 的可靠性因子 r_j 和重要性权重 w_j ^[8]. 可靠性因子 r_j 体现了生成 e_j 的信息源能够对给定问题提供精确评估或解答的能力,它是证据的固有特性;重要性权重 w_j 定义了 e_j 相较于其他证据的相对重要性,它取决于什么样的证据参与融合、由谁来使用这些证据以及证据使用的具体场合^[8,9-12]. 可见,权重 w_j 可根据以上的具体情况主观确定,其意义不一定等同于证据的可靠性. 含有可靠性因子和重要性权重的信度分布函数定义如(2)式所示

$$m_j = \{(\theta, \tilde{m}_{\theta,j}) | \forall \theta \subseteq \Theta; (P(\Theta), \tilde{m}_{P(\Theta),j})\} \quad (2)$$

其中, $\tilde{m}_{\theta,j}$ 为考虑可靠性因子和重要性权重的证据 e_j 对命题 θ 的支持程度,定义如(3)式所示^[8]

$$\tilde{m}_{\theta,j} = \begin{cases} 0 & \theta = \emptyset \\ c_{r,w,j} m_{\theta,j} & \theta \subseteq \Theta, \theta \neq \emptyset \\ c_{r,w,j} (1 - r_j) & \theta = P(\Theta) \end{cases} \quad (3)$$

其中, $m_{\theta,j} = w_j p_{\theta,j}$, $c_{r,w,j} = 1/(1 + w_j - r_j)$ 是归一化因子,其保证了 $\sum_{\theta \subseteq \Theta} \tilde{m}_{\theta,j} + \tilde{m}_{P(\Theta),j} = 1$ 成立,并有 $\sum_{\theta \subseteq \Theta} p_{\theta,j} = 1$. 相比于Shafer提出的证据折扣方法^[7],ER规则中将考虑证据可靠性后得到的剩余信度定义为该证据的不可靠性 $(1 - r_j)$,不是将其预先分配给 Θ 的任何子集,而是在证据融合前将其暂记在幂集 $P(\Theta)$ 的名下,亦即该信度可能支持全集 Θ 及其任何子集,而不是只能支持 Θ . 这也是因为 $p_{\theta,j}$ 是 e_j 的内部特性,应该与其他 θ 一样对待,接受 $c_{r,w,j}$ 的同等折扣. 这样做就可以保持 e_j 和 m_j 具有相同的(概率)特征^[7-8]. 基于上述定义,某个证据的剩余信度反映了该证据的不可靠程度. 因此,证据的剩余信度应该如何分配不是也不能由该证据本身决定,而是取决于与其融合的其他证据的信度分布.

如果两组证据 e_1 和 e_2 是相互独立的,那么可利用ER融合规则对它们进行融合^[8],得到 e_1 和 e_2 联合支持命题 θ 的信度函数 $p_{\theta,e(2)}$,如(4)式所示

$$p_{\theta,e(2)} = \begin{cases} 0 & \theta = \emptyset \\ \frac{\hat{m}_{\theta,e(2)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,e(2)}} & \theta \subseteq \Theta, \theta \neq \emptyset \end{cases} \quad (4)$$

$$\hat{m}_{\theta,e(2)} = [(1 - r_2)m_{\theta,1} + (1 - r_1)m_{\theta,2}] + \sum_{B \cap C = \theta} m_{B,1} m_{C,2} \quad \forall \theta \subseteq \Theta$$

该公式可以递归地用于多条证据以任意顺序的融合.

3 证据推理(ER)故障诊断方法(Evidential Reasoning (ER) fault diagnosis method)

3.1 基于故障样本似然函数归一化的诊断证据获取方法(Diagnosis evidence acquisition method based on normalized likelihood function of fault feature samples)

设故障集合 $\Theta = \{F_1, \dots, F_i, \dots, F_N\}$, F_i 代表故障集合 Θ 中的第 i 个故障, $i=1,2,\dots,N$, N 为故障模式的个数. 设 x 是能够反映故障集合 Θ 中每个故障 F_i 的故障特征变量, 该特征变量的取值由某信息源(传感器)提供. 当每个故障 F_i 发生时获取 x 的 δ 个测量样本, 它们构成的集合为 $V_i^x = \{v_{i,1}^x, v_{i,2}^x, \dots, v_{i,\delta}^x\}$, 分别取其中的最小值和最大值作为 x_i^L 和 x_i^R , 则可得到变量 x 对于 F_i 的取值变化区间 $[x_i^L, x_i^R]$, 共计可以得到 N 个区间 $[x_1^L, x_1^R], [x_2^L, x_2^R], \dots, [x_N^L, x_N^R]$. 将这 N 个区间的 $2N$ 个左右端点按照从小到大的顺序排序, 组成含有 $2N$ 个点的序列 $S = \{s_1, s_2, \dots, s_{2N}\}$, 其中 $s_j \in \{x_1^L, x_1^R, x_2^L, x_2^R, \dots, x_N^L, x_N^R\}$, $j=1,2,\dots,2N$, 按照 s_j 的排序, 生成 x 关于故障集合 Θ 的 $2N-1$ 个样

本变化区间 $I_1^x = [s_1, s_2), I_2^x = [s_2, s_3), \dots, I_{2N-1}^x = [s_{2N-1}, s_{2N})$. 在 N 种故障分别发生时, 可获得 N 种故障的测量样本集合为 $V_1^x = \{v_{1,1}^x, v_{1,2}^x, \dots, v_{1,\delta}^x\}$, $V_2^x = \{v_{2,1}^x, v_{2,2}^x, \dots, v_{2,\delta}^x\}$, \dots , $V_N^x = \{v_{N,1}^x, v_{N,2}^x, \dots, v_{N,\delta}^x\}$, 此外, 若还有 δ' 个测量样本对应的故障模式未知, 则可将它们构成的集合记为 $V_\Theta^x = \{v_{\Theta,1}^x, v_{\Theta,2}^x, \dots, v_{\Theta,\delta'}^x\}$ (表示实际中虽然获得 x 的一些样本, 但是未能判断出其反映的故障模式), 那么共计可获 $(N\delta + \delta')$ 个样本, 并构成 x 的总样本集为

$$V^x = \{V_1^x, V_2^x, \dots, V_N^x, V_\Theta^x\} \quad (5)$$

统计它们在各区间中的投点个数, 可构造出特征变量 x 和故障 F_1, F_2, \dots, F_N 以及全集 Θ 之间的投点矩阵, 如下表1所示, 其中 $l=1,2,\dots,2N-1$ 为样本变化区间的个数, a_{il} 表示故障 F_i 的特征变量 x 的样本在 $[s_l, s_{l+1})$ 中的投点个数, 并有 $\delta = \sum_{l=1}^{2N-1} a_{il}$, $\delta' = \sum_{l=1}^{2N-1} a_{\Theta l}$, η_l 为 $[s_l, s_{l+1})$ 中的样本投点个数的总和, 并有 $\eta_l = \sum_{i=1}^N a_{il} + a_{\Theta l}$.

根据表1, 可获得当故障 F_i 发生或无法判断何种故障(Θ)发生时, x 的取值落入区间 $[s_l, s_{l+1})$ 的似然函数为

$$c(I_l^x|F_i) = \frac{a_{il}}{\delta}, c(I_l^x|\Theta) = \frac{a_{\Theta l}}{\delta'} \quad (6)$$

表 1 故障特征变量 x 的投点矩阵表

Table 1 The casting matrix of fault feature variable x

	故障特征 x 的样本变化区间					总计
	I_1^x	\dots	I_l^x	\dots	I_{2N-1}^x	
	$[s_1, s_2)$	\dots	$[s_l, s_{l+1})$	\dots	$[s_{2N-1}, s_{2N})$	
F_1	a_{11}	\dots	a_{1l}	\dots	$a_{1(2N-1)}$	δ
\vdots	\vdots	\ddots	\vdots	\ddots	\vdots	\vdots
故障 F_i	a_{i1}	\dots	a_{il}	\dots	$a_{i(2N-1)}$	δ
\vdots	\vdots	\ddots	\vdots	\ddots	\vdots	\vdots
类型 F_N	a_{N1}	\dots	a_{Nl}	\dots	$a_{N(2N-1)}$	δ
Θ	$a_{\Theta 1}$	\dots	$a_{\Theta l}$	\dots	$a_{\Theta(2N-1)}$	δ'
总计	η_1	\dots	η_l	\dots	$\eta_{(2N-1)}$	$N\delta + \delta'$

将式(6)中的似然函数进行归一化, 获得当 x 的取值落入区间 I_l^x 时, 故障 F_i 或 Θ 发生的信度为^[13]

$$p_{i,l}^x = \frac{c(I_l^x|F_i)}{\sum_{i=1}^N c(I_l^x|F_i) + c(I_l^x|\Theta)}$$

$$p_{\Theta,l}^x = \frac{c(I_l^x|\Theta)}{\sum_{i=1}^N c(I_l^x|F_i) + c(I_l^x|\Theta)} \quad (7)$$

并有 $\sum_{i=1}^N p_{i,l}^x + p_{\Theta,l}^x = 1$, 则此时获取的诊断证据为

$$e_l^x = [p_{1,l}^x, p_{2,l}^x, \dots, p_{N,l}^x, p_{\Theta,l}^x] \quad (8)$$

给定一个特征变量 x 的取值, 其必然落入 $I_1^x, I_2^x, \dots, I_{2N-1}^x$ 中的某一个, 此时该区间所对应的诊断证据 $e_1^x, e_2^x, \dots, e_{2N-1}^x$ 中的某一个被激活, 则可以被激活的证据的个数为 $2N-1$, 表2给出了相应的证据矩阵

表 2 故障特征参数 x 的证据矩阵表

Table 2 The evidence matrix of fault feature variable

		故障特征 x 的诊断证据				
		e_1^x	\cdots	e_l^x	\cdots	e_{2N-1}^x
		I_1^x	\cdots	I_l^x	\cdots	I_{2N-1}^x
故障 类型	F_1	$p_{1,1}^x$	\cdots	$p_{1,l}^x$	\cdots	$p_{1,2N-1}^x$
	\vdots	\vdots	\ddots	\vdots	\ddots	\vdots
	F_i	$p_{i,1}^x$	\cdots	$p_{i,l}^x$	\cdots	$p_{i,2N-1}^x$
	\vdots	\vdots	\ddots	\vdots	\ddots	\vdots
	F_N	$p_{N,1}^x$	\cdots	$p_{N,l}^x$	\cdots	$p_{N,2N-1}^x$
	Θ	$p_{\Theta,1}^x$	\cdots	$p_{\Theta,l}^x$	\cdots	$p_{\Theta,2N-1}^x$

3.2 证据可靠性因子的获取方法(The method of calculating evidence reliability)

在本文中,我们考虑了影响证据生成的两方面因素,第一个因素是所划分的证据区间对于各个故障模式及全集 Θ 的辨识能力, e_l^x 对某一故障模式的辨识能力越强,就意味着它对于该故障模式的信度赋值就越大,对其他故障模式的信度赋值越小. 如果 e_l^x 对各个故障模式及 Θ 的赋值均等($1/(N+1)$),那么说明 e_l^x 对诊断不能提供任何有用的信息. 所以定义“无信息信度向量”为 $\gamma = [1/(N+1), 1/(N+1), \cdots, 1/(N+1)]$,则可以求取 e_l^x 与 γ 之间的欧氏距离 $d_E(e_l^x, \gamma)$ 用于度量 e_l^x 的辨识能力

$$Rf_l^x = d_E(e_l^x, \gamma) \in [0, 1] \quad (9)$$

显然, Rf_l^x 越小说明 e_l^x 越趋近于 γ ,则其含有的信息量越小,则辨识故障的能力越弱,反之则越强.

第二个因素涉及到用于采集特征变量 x 的传感器(信息源)本身的可靠性. 传感器的可靠性,可以由其观测误差所决定. 证据集合 $E^x = \{e_l^x | l = 1, 2, \dots, 2N-1\}$ 是基于样本变化区间 I_l^x 生成的. 在实际获取测量样本的过程中,数据的读取往往伴随着 $\pm\Delta\%$ 的观测误差,因此,我们在从传感器获取样本时,对每个样本添加 $\Delta\%$ 或 $-\Delta\%$ 的扰动,计算这些含有扰动的样本不再落入 I_l^x 的个数,记作 σ_l ,并有 $\sigma_l \leq \eta$. σ_l 越大,说明投点过程可靠性低,那么相应生成的证据 e_l^x 也越不可靠. 那么可以定义由传感器误差和样本区间投点误差引起的 e_l^x 可靠性因子为

$$Rn_l^x = \frac{\eta - \sigma_l}{\eta} \in [0, 1] \quad (10)$$

最后,证据 e_l^x 的综合可靠性因子 r_l^x 可由(9)式和(10)式合成得到

$$r_l^x = Rf_l^x \times Rn_l^x \in [0, 1] \quad (11)$$

显然, r_l^x 越大,则生成的证据 e_l^x 越可靠.

3.3 基于双目标优化模型的证据重要性权重训练方法(The method of training evidence weights based on a bi-objective optimization model)

我们假设可利用传感器获得三种故障特征变量 x_1, x_2, x_3 的样本, 辨识集合 $\Theta = \{F_1, \dots, F_i, \dots, F_N\}$ 中的故障. 在此假设下,说明如何构建优化模型获取证据的重要性权重. 由3.1节提供的方法可生成三组证据集合 $E^k = \{e_l^k | l = 1, 2, \dots, 2N-1\}$, $k = 1, 2, 3$,表示故障特征的个数,那么需要训练的证据重要性权重为

$$W = \{w_l^k | l = 1, 2, \dots, 2N-1, k = 1, 2, 3\} \quad (12)$$

将由(5)式获取的测量样本集合整合为关于 x_1, x_2, x_3 的训练样本向量

$$V = \{[v_j^1, v_j^2, v_j^3] | v_j^k \in V^{x_k}, j = 1, 2, \dots, (N\delta + \delta'), k = 1, 2, 3\}$$

对于训练样本集合中的某一个样本向量,它必定激活某一诊断证据组合,例如“ $e_3^{x_1}, e_4^{x_2}, e_2^{x_3}$ ”. 因此,所有可能被激活的证据组合的总数为 $Q = (2N-1)^3$.

利用ER规则可以得到第 q 组证据组合的融合结果,记为 $e_{q,e(3)} = [p_{1,e(3)}^q, p_{2,e(3)}^q, \dots, p_{N,e(3)}^q, p_{\Theta,e(3)}^q]$, $q = 1, 2, \dots, Q$,则可以定义 $e_{q,e(3)}$ 与实际发生的故障模式之间的距离为

$$D_o(W) = \sum_{q=1}^Q (n_{1,q}D_{1,q} + n_{2,q}D_{2,q} + \dots + n_{N,q}D_{N,q} + n_{\Theta,q}D_{\Theta,q}) \quad (13)$$

其中, $n_{i,q}$ 表示第 q 种组证据组合中,当 F_i 发生时对应的训练样本向量的个数,并有 $\delta = \sum_{q=1}^Q n_{i,q}$, $\delta' = \sum_{q=1}^Q n_{\Theta,q}$,所以表1中的 $(N\delta + \delta')$ 个训练样本都参与了 $D_o(W)$ 的运算

$$\begin{aligned} D_{i,q} &= d_E(P_{q,e(3)}, \alpha_i) \\ D_{\Theta,q} &= d_E(P_{q,e(3)}, \alpha_{\Theta}) \end{aligned} \quad (14)$$

其中, α_i 是第 i 个元素为1其它元素为0的 $N+1$ 维向量, α_{Θ} 是第 $N+1$ 个元素为1,其他元素为0的向量. α_i 和 α_{Θ} 是参考向量,表示故障 F_i 或 Θ 真实发生,对其的信度赋值为1. d_E 表示融合结果与参考向量之间的欧式距离,它度量了 $P_{q,e(3)}$ 和真实发生的故障 F_i 或 Θ 之间的距离. $D_o(W)$ 综合度量了 Q 种组合所得融合结果支持真实发生故障的程度. $D_o(W)$ 越小则故障确诊率越高,反之则越低.

仅仅通过最小化 $D_o(W)$ 得到最优参数集 W 是不全面的,因为即使对应于 w_l^k 的 e_l^k 有较高的可靠性,片面地最小化 $D_o(W)$ 可能会引起该 $w_l^k \in W$ 接近最小值0,相反地,当 e_l^k 可靠性较低时,仍会引

起 $w_i^k \in W$ 接近最大值1,从而出现有悖常理的 w_i^k 取值. 为了避免这种情况,我们引入另一距离,权重 w_i^k 和其参考值 \bar{w}_i^k 之间的距离

$$D_r(W) = \sum_{k=1}^K d_E(W^k, \bar{W}^k) \quad (15)$$

其中, $W^k = [w_1^k, w_2^k, \dots, w_{2N+1}^k]$, $\bar{W}^k = [\bar{w}_1^k, \bar{w}_2^k, \dots, \bar{w}_{2N+1}^k]$, 后者是前者的参考值. 这里设定参考值 $\bar{w}_i^k = r_i^k$, 因为从可靠性因子 r_i^k 的实际意义可以看出, 当某一证据的可靠性高于其他证据时, 在融合过程中它应该具有较高的重要性权重.

那么, 就可以将(13)式和(15)式两种度量标准相结合, 构成一个形如(16)式的双目标优化模型

$$\min_W (a \times RC_o + (1 - a) \times RC_r) \quad (16)$$

通过最小化上式的取值找到最优的重要性权重集合 W , 其中, $0 \leq w_i^k \leq 1$, $RC_o = \frac{D_o - D_o^-}{D_o^+ - D_o^-}$, $RC_r = \frac{D_r - D_r^-}{D_r^+ - D_r^-}$, RC_o 和 RC_r 分别是 $D_o(W)$ 和 $D_r(W)$ 的相对变化值. 偏好权重 $a \in [0, 1]$ 和 $(1-a)$ 可以用来调整在不同应用背景下 RC_o 和 RC_r 两个评价指标的综合指标中的比

重. 通过将 $w_i^k = r_i^k$ 代入(13)式可获得 D_o 的最大值 D_o^+ , 此时 $D_r^- = 0$. D_o 的最小值 D_o^- 是在 $0 \leq w_i^k \leq 1$ 的约束下, 通过最小化 $D_o(W)$ 获得, 然后将 D_o^- 对应的 W 带入(15)式即可求得相应的 D_r^+ . 最优的 W 可通过基于梯度的搜索方法或者非线性优化软件包(如Matlab软件优化工具中的 $fmincon$ 函数)求得. 在获得最优的 W 之后, 即可利用ER融合规则计算出融合结果 $P_{q,e(3)} = [p_{1,e(3)}^q, p_{2,e(3)}^q, \dots, p_{N,e(3)}^q, p_{\Theta,e(3)}^q]$, 然后, 基于以下决策准则来给出诊断结果:

准则1: 如果 $\max(p_{1,e(3)}^q, p_{2,e(3)}^q, \dots, p_{N,e(3)}^q) = p_{i,e(3)}^q$, 那么故障特征向量对应的融合结果指向故障类型 F_i ;

准则2: 如果 $\max(p_{1,e(3)}^q, p_{2,e(3)}^q, \dots, p_{N,e(3)}^q) = p_{\Theta,e(3)}^q$, 那么故障特征向量对应的融合结果指向“故障可能是 Θ 中的任何一个”, 亦即无法做出决策.

利用以上准则获得的决策结果, 可以构造出如表3所示的故障决策混淆矩阵.

表 3 融合诊断故障决策的混淆矩阵

Table 3 The confusion matrixes of fused diagnosis decision-making

		融合故障诊断结果						总计
		F_1	\dots	F_i	\dots	F_N	Θ	
故障 类型	F_1	$n_{1,1}$	\dots	$n_{1,i}$	\dots	$n_{1,N}$	$n_{1,\Theta}$	δ
	\vdots	\vdots	\ddots	\vdots	\ddots	\vdots	\vdots	\vdots
	F_i	$n_{i,1}$	\dots	$n_{i,i}$	\dots	$n_{i,N}$	$n_{i,\Theta}$	δ
	\vdots	\vdots	\ddots	\vdots	\ddots	\vdots	\vdots	\vdots
	F_N	$n_{N,1}$	\dots	$n_{N,i}$	\dots	$n_{N,N}$	$n_{N,\Theta}$	δ
	Θ	$n_{\Theta,1}$	\dots	$n_{\Theta,i}$	\dots	$n_{\Theta,N}$	$n_{\Theta,\Theta}$	δ'

表3中, $n_{s,t}(s, t = 1, 2, \dots, N, \Theta)$ 表示真实故障类型为 F_s 或者未知 Θ , 而训练样本对应的融合结果支持各故障模式 F_t 或 Θ 的个数, 当 $s=t$ 时, 则表明故障样本被正确诊断.

当使用(16)式的双目标优化模型获得最优的 W 时, 需要给定偏好权重值 a . a 的选择应遵循“正确诊断的训练样本个数 $R_c = n_{1,1} + n_{2,2} + \dots + n_{N,N} + n_{\Theta,\Theta}$ (混淆矩阵对角线元素之和)最大化”的准则. 基于此可以通过以下步骤来获取最优偏好权重 a :

(1)令权重 w_i^k 的取值范围为 $[0,1]$, 且初值为1, 再利用(13)式和(15)式求得 D_o^+ , D_o^- , D_r^+ , D_r^- ;

(2)以0.2的步长在0到1之间遍历 a 的取值, 进行双目标优化可获得 $a=0.2, 0.4, 0.6, 0.8$ 时的混淆矩阵, 依照前述的规则, 选择其中最佳的 a ;

(3)以步骤(2)中选取的 a 为中心构造更精确的新搜寻区间, 并以 $0.2/2^n$ 为步长重复步骤(2), n 为步骤(2)的重复次数, 直到当前区间中所有偏好权重 a 对应的混淆矩阵都相同, 则可选取该区间的中点或任意一点作为最优偏好权重 a 的取值.

4 在电机转子故障诊断中的实验验证(A diagnosis experiment on a motor rotor test bed)

4.1 电机转子实验设置(The experimental setup of motor rotor)

本文以电机转子故障诊断为例验证本文方法的有效性. 实验设备为ZHS-2型多功能柔性转子试验台, 将振动位移传感器和加速度传感器分别安置在转子支撑座的水平和垂直方向采集转子振动信号, 经HG-8902采集箱将信号传输至计算机, 然后利用Labview环境下的HG-8902数据分析软件得到转子振动加速度频谱以及时域振动位移平均幅值作为故障特征信号^[1,4].

分别在试验台上设置以下4种典型故障模式: 正常运行 F_1 , 转子不平衡 F_2 , 转子不对中 F_3 , 基座松动 F_4 . 通过对大量实验数据的分析可知, 引发异常振动的故障源都会产生一定频率成分的振动幅值增加或减少^[1]. 因此, 这里选取1X~3X倍频以及时域振动位移平均幅值作为故障特征变量. 设定转子转速为1500r/m, 则基频1X为25Hz, n 倍频 nX , $n=1,2,3,\dots$, 为 $(n \times 25)$ Hz. 将频域的1X~3X的振动幅值以及时域振动位移4种特征信息进行综合做出决策. 实验中, 所选取的振动传感器的观测误差为 $\Delta = \pm 1\%$.

4.2 求取诊断证据及其可靠性因子(Calculating diagnosis evidence and reliability)

利用第3.1节的方法, 首先可确定本实验中的故障辨识框架为 $\Theta = \{F_1, F_2, F_3, F_4\}$. 对于1X、2X、3X的幅值和时域振动位移平均幅值这4个特征变量, 分别在4种故障模式下, 以时间间隔 $\Delta t = 16s$ 连续采集 $\delta = 500$ 次测量值, 即可获得2000个测量(训练)样本, 用于建立故障特征变量关于4种故障的 $2N-1=7$ 个样本变化区间, 那么可以得到4种特征变量对应4种故障, 共4组28个样本变化区间, 相应的投点矩阵如表4~7所示. 需要注意的是, 因为这些故障数据都是在故障实验中获取, 不存在样本对应故障模式未知的情况, 所以全集 Θ 在各个区间中没有投点样本. 其中, $I_1^{1X} = [0.0681, 0.1517)$, $I_2^{1X} = [0.1517, 0.1567)$, $I_3^{1X} = [0.1567, 0.1602)$, $I_4^{1X} = [0.1602, 0.1706)$, $I_5^{1X} = [0.1706, 0.2006)$, $I_6^{1X} = [0.2006, 0.2050)$, $I_7^{1X} = [0.2050, 0.2176)$; $I_1^{2X} = [0.0403, 0.1422)$, $I_2^{2X} = [0.1422, 0.1478)$, $I_3^{2X} = [0.1478, 0.1571)$, $I_4^{2X} = [0.1571, 0.1621)$, $I_5^{2X} = [0.1621, 0.1865)$, $I_6^{2X} = [0.1865, 0.2010)$, $I_7^{2X} = [0.2010, 0.2147)$;

$$\begin{aligned} I_1^{3X} &= [0.0446, 0.1179), I_2^{3X} = [0.1179, 0.1327), \\ I_3^{3X} &= [0.1327, 0.1365), I_4^{3X} = [0.1365, 0.1707), \\ I_5^{3X} &= [0.1707, 0.1754), I_6^{3X} = [0.1754, 0.2096), \\ I_7^{3X} &= [0.2096, 0.2718); I_1^{\text{位移}} = [3.6010, 3.9090), \\ I_2^{\text{位移}} &= [3.9090, 4.0004), I_3^{\text{位移}} = [4.0004, 4.2900), \\ I_4^{\text{位移}} &= [4.2900, 4.3850), I_5^{\text{位移}} = [4.3850, 4.8510), \\ I_6^{\text{位移}} &= [4.8510, 5.0673), I_7^{\text{位移}} = [5.0673, 5.2160). \end{aligned}$$

根据训练样本的投点矩阵, 我们可以通过(6)式得到相应的似然函数, 并用(7)式对似然函数归一化得到证据 $e_l^x = [p_{1,l}^x, p_{2,l}^x, p_{3,l}^x, p_{4,l}^x, p_{\Theta,l}^x]$, 这里故障特征 $x \in \{1X, 2X, 3X, \text{位移}\}$, $l=1,2,\dots,7$, 如表8~11所示.

在获得证据矩阵的基础上, 分别用(9)式和(10)式计算可靠性因子 Rf_l^k 和 Rn_l^k , 然后由(11)式获得各信息源的综合可靠性因子 r_l^k , 求取结果分别如表12~15所示.

4.3 求取证据权重(Acquiring evidence weights)

为了利用(16)式的双目标优化模型求取最优证据权重 $W = \{w_l^x | l = 1, 2, \dots, 7\}$, 首先需要获得合适的偏好权重 a , 因此, 我们结合3.3节中给出的方法来选择最优偏好权重值 a , 过程如下:

(1)令 w_l^x 的取值范围为 $[0,1]$, 初始值为1, 并且对上节中获得的训练样本数据, 利用(13)式和(15)式, 求出 $D_o^+ = 604.2229$, $D_o^- = 344.3431$, $D_r^+ = 4.7363$, $D_r^- = 0$.

(2)在0到1之间, 以0.2为步长遍历所有在 a 的取值, 根据(16)式的双目标优化模型, 即可得到 $a=0.2, 0.4, 0.6, 0.8$ 时的混淆矩阵, 分别如表16和表17所示. 显然, $a=0.4$ 时的混淆矩阵确诊的故障样本数量最多, 即有最大的对角线元素和 R_c , 因此, $a=0.4$ 是它们中最佳的偏好权重值.

(3)以 $a=0.4$ 为中心构建新的搜寻区间 $[0.2,0.6]$, 并在此区间内以0.2/2的步长重复第(2)步, 计算得到的最佳偏好权重值 a 仍为0.4.

(4)重复过程(3)得到更精确的搜寻区间, 同时逐步缩小步长, 在相应区间内搜寻最优的偏好权重值 a , 直到当步长缩短到 $2/2^4$ 时的搜寻区间中所有 a 值对应产生的混淆矩阵都是相同的, 此时取该区间的中点 $a=0.4$ 作为我们最终的最优偏好权重值.

给定 $a=0.4$ 时, 附录表A1列出了被激活的证据组合, 以及基于初始权重和训练权重的融合诊断结果, 附录表A2列出了基于初始权重和训练权重的融合诊断证据. 初始权重和训练权重下获得的混淆矩阵如表18所示, 各故障特征对应证据的训练权重 w_l^x 取值如表19所示.

表 4 关于故障特征变量1X的投点矩阵
Table 4 The casting matrix of fault feature variable 1X

		故障特征1X的样本变化区间							总计
		I_1^{1X}	I_2^{1X}	I_3^{1X}	I_4^{1X}	I_5^{1X}	I_6^{1X}	I_7^{1X}	
故障类型	F_1	494	4	1	1	0	0	0	500
	F_2	0	53	107	318	21	1	0	500
	F_3	0	0	10	66	417	6	1	500
	F_4	0	0	0	0	332	102	66	500
	Θ	0	0	0	0	0	0	0	0
总计		494	57	118	385	770	109	67	2000

表 5 关于故障特征变量2X的投点矩阵
Table 5 The casting matrix of fault feature variable 2X

		故障特征2X的样本变化区间							总计
		I_1^{2X}	I_2^{2X}	I_3^{2X}	I_4^{2X}	I_5^{2X}	I_6^{2X}	I_7^{2X}	
故障类型	F_1	498	0	1	0	1	0	0	500
	F_2	0	3	6	35	455	1	0	500
	F_3	0	0	0	6	359	134	1	500
	F_4	0	0	7	1	69	297	126	500
	Θ	0	0	0	0	0	0	0	0
总计		498	3	14	42	884	432	127	2000

表 6 关于故障特征变量3X的投点矩阵
Table 6 The casting matrix of fault feature variable 3X

		故障特征3X的样本变化区间							总计
		I_1^{3X}	I_2^{3X}	I_3^{3X}	I_4^{3X}	I_5^{3X}	I_6^{3X}	I_7^{3X}	
故障类型	F_1	480	19	1	0	0	0	0	500
	F_2	0	0	0	0	0	499	1	500
	F_3	0	0	0	159	24	177	140	500
	F_4	0	214	104	181	1	0	0	500
	Θ	0	0	0	0	0	0	0	0
总计		480	233	105	340	25	676	141	2000

表 7 关于时域振动位移平均幅值的投点矩阵
Table 7 The casting matrix of fault feature variable “displacement”

		故障特征”位移”的样本变化区间							总计
		$I_1^{\text{位移}}$	$I_2^{\text{位移}}$	$I_3^{\text{位移}}$	$I_4^{\text{位移}}$	$I_5^{\text{位移}}$	$I_6^{\text{位移}}$	$I_7^{\text{位移}}$	
故障类型	F_1	386	113	1	0	0	0	0	500
	F_2	0	0	0	2	497	1	0	500
	F_3	0	9	88	73	290	37	3	500
	F_4	0	0	0	0	319	180	1	500
	Θ	0	0	0	0	0	0	0	0
总计		386	122	89	75	1106	218	4	2000

表 8 关于故障特征1X的证据矩阵
Table 8 The evidence matrix of fault feature 1X

		故障特征1X的诊断证据						
		e_1^{1X}	e_2^{1X}	e_3^{1X}	e_4^{1X}	e_5^{1X}	e_6^{1X}	e_7^{1X}
证据 e_l^{1X}	F_1	1	0.0702	0.0085	0.0026	0	0	0
	F_2	0	0.9298	0.9068	0.8260	0.0273	0.0092	0
	F_3	0	0	0.0847	0.1714	0.5416	0.055	0.0149
	F_4	0	0	0	0	0.4312	0.9358	0.9851
	Θ	0	0	0	0	0	0	0

表 9 关于故障特征2X的证据矩阵
Table 9 The evidence matrix of fault feature 2X

		故障特征2X的诊断证据						
		e_1^{2X}	e_2^{2X}	e_3^{2X}	e_4^{2X}	e_5^{2X}	e_6^{2X}	e_7^{2X}
证据 e_l^{2X}	F_1	1	0	0.0714	0	0.0011	0	0
	F_2	0	1	0.4286	0.8333	0.5147	0.0023	0
	F_3	0	0	0	0.1429	0.4061	0.3102	0.0079
	F_4	0	0	0.5	0.0238	0.0781	0.6875	0.9921
	Θ	0	0	0	0	0	0	0

表 10 关于故障特征3X的证据矩阵
Table 10 The evidence matrix of fault feature 3X

		故障特征3X的诊断证据						
		e_1^{3X}	e_2^{3X}	e_3^{3X}	e_4^{3X}	e_5^{3X}	e_6^{3X}	e_7^{3X}
证据 e_l^{3X}	F_1	1	0.0815	0.0095	0	0	0	0
	F_2	0	0	0	0	0	0.7382	0.0071
	F_3	0	0	0	0.4676	0.96	0.2618	0.9929
	F_4	0	0.9185	0.9905	0.5324	0.04	0	0
	Θ	0	0	0	0	0	0	0

表 11 故障特征“位移”的证据矩阵
Table 11 The evidence matrix of fault feature “displacement”

		故障特征“位移”的诊断证据						
		$e_1^{\text{位移}}$	$e_2^{\text{位移}}$	$e_3^{\text{位移}}$	$e_4^{\text{位移}}$	$e_5^{\text{位移}}$	$e_6^{\text{位移}}$	$e_7^{\text{位移}}$
证据 $e_l^{\text{位移}}$	F_1	1	0.9262	0.0112	0	0	0	0
	F_2	0	0	0	0.0267	0.4494	0.0046	0
	F_3	0	0.0738	0.9888	0.9733	0.2622	0.1697	0.75
	F_4	0	0	0	0	0.2884	0.8257	0.25
	Θ	0	0	0	0	0	0	0

表 12 关于故障特征1X的可靠性因子
Table 12 The reliability indices of fault feature 1X

	I_1^{1X}	I_2^{1X}	I_3^{1X}	I_4^{1X}	I_5^{1X}	I_6^{1X}	I_7^{1X}
Rf_l^{1X}	0.8944	0.8182	0.7934	0.7153	0.5291	0.8239	0.8778
Rn_l^{1X}	0.9939	0.4737	0.0847	0.6260	0.8610	0.0459	0.7313
r_l^{1X}	0.8890	0.3876	0.0672	0.4477	0.4556	0.0378	0.6420

从附录表A1中可以看出除“正常模式 F_1 ”之外,其他三种故障类型之间不可避免地存在着不同程度的混淆,但是通过训练过程可以明显地降低混淆程度.附录表A1中灰底的证据组合中初始 W 和训练 W 下的融合诊断结果是不同的,例如证据组合1608_{th}中,诊断结果由故障 F_2 (少数样本支持)改变为故障 F_3 (多数样本支持),而证据组合1640_{th}中,诊断结果由故障 F_4 (无样本支持)改变为故障 F_3 .同样地,其它灰底的证据组合1214_{th}, 1643_{th}, 1651_{th}也体现了训练 W 起到的类似作用.因此,训练 W 后获得的混淆矩阵明显优于初始 W 下的混淆矩阵,即训练得到的混淆矩阵中对角线元素之和 R_c 明显大于初始 W 下的混淆矩阵.

4.4 方法测试与分析(Test and analysis of the method)

一旦双目标优化过程完成,可将附录表A1中的1~5列和第10列,以及附录表A2中的2~6列重新组合构成“融合系统决策表”.任意一组故障特征 $1X$, $2X$, $3X$, “位移”的样本都会激活决策表中的某一种证据组合,那么诊断结果就可通过查询决策表直接得到.我们用与获得训练样本同样的方法,再通过实验获得1200组样本来测试“融合系统决策表”的诊断效果,其中,故障 F_1 , F_2 , F_3 , F_4 各300组样本.查表后获取的测试样本的混淆矩阵如表20所示.

从表20中可以看出, $R_c|_{\text{初始}W} = 1108 < R_c|_{\text{训练}W} = 1133$.训练前和训练后相比,后者在 F_2 和 F_4 确诊个数少量降低的前提下大幅增加了 F_3 的确诊个数.因此,基于ER规则训练权重后的融合系统从总体上有效地降低了各故障类型之间的混淆程度.

5 总结(Conclusion)

本文针对多源不确定性故障特征信息融合决策问题,给出基于ER规则的故障诊断方法.首先基于故障特征样本似然函数归一化的方法求取各传感器(信息源)的诊断证据;从传感器误差以及故障特征对各故障类型辨别能力的差异出发,给出获取诊断证据可靠性因子的方法;给出双目标优化模型训练得到诊断证据的重要性权重,最后利用ER融合规则融合经可靠性因子和重要性权重修正后的诊断证据,利用融合结果进行故障决策.

该方法继承了Dempster-Shafer证据理论处理不确定性信息融合问题的优点,同时克服了它在实际应用中无法考虑证据可靠性和重要性的不足,其优点在于:(1)所提方法是数据驱动的方法,不需要对故障特征变化规律以及特征与故障模式之间的映射

关系做出任何假设;(2)算法中的证据可靠性、证据重要性概念明确,对它们的求取方法物理意义明确,便于实际工程技术人员的理解以及对新方法的应用推广;(3)诊断证据严格地通过基于样本的统计推理获得,不需要人为给定诊断证据,减少了由专家提供证据所引起的证据不精确和不可靠;(4)一旦获得“融合系统决策表”,随后的诊断结果查表即可得到,不需要重复运算.

此外,本文给出的实验例子中,并未对全集(完全未知)赋予信度,而实际中确实会存在虽然得到故障样本,但无法或未能确定其所支持的故障或故障子集的情况,未来的研究中,可以就该方面对所提算法进行进一步的验证与推广.对于不同的传感器结构及设置,以及不同的融合诊断意图,也可以进一步讨论证据可靠性因子和证据权重的其他获取方法,从而使得所提方法可以应用于更多的情况和领域.

参考文献(References):

- [1] 文成林, 徐晓滨. 多源不确定信息融合理论及应用-故障诊断与可靠性评估[M]. 北京: 科学出版社, 2012.
(WEN Chenglin, XU Xiaobin. *Multi-source Uncertain Information Fusion Theory and Application-Fault Diagnosis and Reliability Evaluation*[M]. Beijing: Science Press, 2012.)
- [2] OUKHELLOU L, DEBIOLLES A, DENOEUUX T, AKNIN P. Fault diagnosis in railway track circuits using Dempster - Shafer classifier fusion[J]. *Engineering Applications of Artificial Intelligence*, 2010, 23(1): 117 - 128.
- [3] XU X, ZHOU Z, WEN C L. Data fusion algorithm of fault diagnosis considering sensor measurement uncertainty[J]. *International Journal on Smart Sensing and Intelligent System*, 2013, 6(1): 171 - 190.
- [4] 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 Xiaobin, 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.)
- [5] XU Xiaobin, LIU Ping, SUN Yanbo, WEN Chenglin. Fault diagnosis based on the updating strategy of interval-valued belief structures[J]. *Chinese Journal of Electronics*, 2014, 23(4): 753 - 760.
- [6] 徐晓滨, 王玉成, 文成林. 基于诊断证据可靠性评估的信息融合故障诊断方法[J]. 控制理论与应用, 2011, 28(4): 504 - 510.
(XU Xiaobin, WANG Yucheng, WEN Chenglin. Information - fusion method for fault diagnosis based on reliability evaluation of evidence[J]. *Control Theory & Applications*, 2011, 28(4): 504 - 510.)
- [7] SHAFER G. *A mathematical theory of evidence*[M]. USA: Princeton University Press, 1976.
- [8] YANG J B, XU D L. Evidence reasoning rule for evidence combination[J]. *Artificial Intelligence*, 2013, 205: 1 - 29.
- [9] SI Xiaosheng, HU Changhua, YANG Jianbo, ZHANG Qi. On the dynamic evidential reasoning algorithm for fault prediction[J]. *Expert Systems with Applications*, 2011, 38: 5061 - 5081.
- [10] KONG Guilian, XU Dongling, YANG Jianbo, MA Xiemin. Combined medical quality assessment using the evidential reasoning approach[J]. *Expert Systems with Applications*, 2015, 42: 5522 - 5530.

[11] YANG Guoliang, YANG Jianbo, LIU Wenbin, LI Xiaoxuan. Cross-efficiency aggregation in DEA models using the evidential-reasoning approach[J]. *European Journal of Operational Research*, 2013, 231: 393 – 404.

[12] NGAN S C. Evidential Reasoning approach for multiple-criteria decision making: A simulation-based formulation[J]. *Expert Systems with Applications*, 2015, 42: 4381 – 4396.

[13] YANG J B, XU D L. A study on generalizing Bayesian inference to evidential reasoning[M]//*Belief Function: Theory and Applications*. New York, American: Springer, 2014: 180 – 189.

博士生导师,研究方向为不确定信息处理、智能故障诊断, E-mail: xuxiaobin1980@163.com;

郑进 (1992—),男,杭州电子科技大学自动化学院,控制科学与工程专业,研究方向为不确定信息处理、智能故障诊断, E-mail: zjlinkin@163.com;

徐冬玲 (1962—),女,英国曼彻斯特大学商学院,决策及系统科学教授,研究方向为多目标决策、统计故障检测、复杂系统与过程建模, E-mail: ling.xu@mbs.ac.uk;

杨剑波 (1961—),男,英国曼彻斯特大学商学院,决策及系统科学教授,研究方向为证据推理、多属性决策、多目标优化、人工智能与系统工程,以及相关工程与管理系统的仿真与控制方面的应用研究, E-mail: jian-bo.yang@manchester.ac.uk.

附录(Appendix)

见表A1和表A2.

作者简介:

徐晓滨 (1980—),男,杭州电子科技大学自动化学院,副教授,硕

表 A1 被激活的证据组合及融合诊断结果
Table A1 The activated evidential combinations and the fused diagnosis result

编号 q^{th}	证据组合				F_1	投点数				融合诊断结果 F_i	
	e_l^{1X}	e_l^{2X}	e_l^{3X}	$e_l^{位移}$		F_2	F_3	F_4	训练 W	初始 W	
1	1	1	1	1	368	0	0	0	1	1	
2	1	1	1	2	103	0	0	0	1	1	
3	1	1	1	3	1	0	0	0	1	1	
8	1	1	2	1	14	0	0	0	1	1	
9	1	1	2	2	5	0	0	0	1	1	
16	1	1	3	2	1	0	0	0	1	1	
100	1	3	1	2	1	0	0	0	1	1	
197	1	5	1	1	1	0	0	0	1	1	
344	2	1	1	1	3	0	0	0	1	1	
345	2	1	1	2	1	0	0	0	1	1	
579	2	5	6	5	0	52	0	0	2	2	
580	2	5	6	6	0	1	0	0	2	2	
688	3	1	1	2	1	0	0	0	1	1	
873	3	4	6	5	0	24	0	0	2	2	
880	3	4	7	5	0	0	1	0	3	3	
922	3	5	6	5	0	83	0	0	2	2	
929	3	5	7	5	0	0	9	0	3	3	
1031	4	1	1	2	1	0	0	0	1	1	
1167	4	3	6	5	0	2	0	0	2	2	
1214	4	4	6	3	0	0	1	0	3	2	
1216	4	4	6	5	0	5	0	0	2	2	
1221	4	4	7	3	0	0	3	0	3	3	
1264	4	5	6	4	0	1	1	0	2	2	
1265	4	5	6	5	0	309	1	0	2	2	
1266	4	5	6	6	0	0	2	0	2	2	
1270	4	5	7	3	0	0	14	0	3	3	
1271	4	5	7	4	0	0	4	0	3	3	
1272	4	5	7	5	0	0	30	0	3	3	

编号 d^{th}	e_l^{1X}	证据组合			$e_l^{位移}$	投点数				融合诊断结果 F_i	
		e_l^{2X}	e_l^{3X}	F_1		F_2	F_3	F_4	训练 W	初始 W	
1273	4	5	7	6	0	0	9	0	3	3	
1274	4	5	7	7	0	0	1	0	3	3	
1314	4	6	6	5	0	1	0	0	2	2	
1461	5	2	6	5	0	2	0	0	2	2	
1496	5	3	4	5	0	0	0	6	4	4	
1504	5	3	5	6	0	0	0	1	4	4	
1509	5	3	6	4	0	1	0	0	4	3	
1510	5	3	6	5	0	3	0	0	4	2	
1538	5	4	3	5	0	0	0	1	4	4	
1558	5	4	6	4	0	0	1	0	3	3	
1559	5	4	6	5	0	6	0	0	2	2	
1580	5	5	2	5	0	0	0	9	4	4	
1581	5	5	2	6	0	0	0	12	4	4	
1587	5	5	3	5	0	0	0	5	4	4	
1588	5	5	3	6	0	0	0	7	4	4	
1592	5	5	4	3	0	0	8	0	3	3	
1593	5	5	4	4	0	0	5	0	3	3	
1594	5	5	4	5	0	0	61	11	3	3	
1595	5	5	4	6	0	0	7	11	4	4	
1599	5	5	5	3	0	0	2	0	3	3	
1600	5	5	5	4	0	0	3	0	3	3	
1601	5	5	5	5	0	0	10	0	3	3	
1606	5	5	6	3	0	0	15	0	3	3	
1607	5	5	6	4	0	0	26	0	3	3	
1608	5	5	6	5	0	9	86	0	3	2	
1609	5	5	6	6	0	0	1	0	4	3	
1610	5	5	6	7	0	0	1	0	3	3	
1613	5	5	7	3	0	0	6	0	3	3	
1614	5	5	7	4	0	0	22	0	3	3	
1615	5	5	7	5	0	0	31	0	3	3	
1616	5	5	7	6	0	0	3	0	3	3	
1617	5	5	7	7	0	0	1	0	3	3	
1629	5	6	2	5	0	0	0	91	4	4	
1630	5	6	2	6	0	0	0	37	4	4	
1636	5	6	3	5	0	0	0	33	4	4	
1637	5	6	3	6	0	0	0	14	4	4	
1640	5	6	4	2	0	0	8	0	3	4	
1641	5	6	4	3	0	0	19	0	3	3	
1642	5	6	4	4	0	0	7	0	3	3	
1643	5	6	4	5	0	0	24	8	3	4	
1644	5	6	4	6	0	0	12	10	4	4	
1648	5	6	5	3	0	0	5	0	3	3	
1649	5	6	5	4	0	0	1	0	3	3	
1650	5	6	5	5	0	0	1	0	3	3	
1651	5	6	5	6	0	0	2	0	3	4	
1654	5	6	6	2	0	0	1	0	3	3	
1655	5	6	6	3	0	0	8	0	3	3	
1656	5	6	6	4	0	0	3	0	3	3	
1657	5	6	6	5	0	0	30	0	3	3	
1664	5	6	7	5	0	0	6	0	3	3	
1678	5	7	2	5	0	0	0	26	4	4	
1679	5	7	2	6	0	0	0	10	4	4	
1685	5	7	3	5	0	0	0	8	4	4	
1686	5	7	3	6	0	0	0	10	4	4	
1692	5	7	4	5	0	0	0	16	4	4	
1693	5	7	4	6	0	0	1	6	4	4	
1811	6	2	7	5	0	1	0	0	3	3	
1923	6	5	2	5	0	0	0	5	4	4	
1930	6	5	3	5	0	0	0	2	4	4	
1938	6	5	4	6	0	0	0	1	4	4	
1972	6	6	2	5	0	0	0	18	4	4	
1973	6	6	2	6	0	0	0	2	4	4	
1979	6	6	3	5	0	0	0	18	4	4	
1984	6	6	4	3	0	0	6	0	3	3	
1986	6	6	4	5	0	0	0	9	4	4	
1987	6	6	4	6	0	0	0	7	4	4	
2021	6	7	2	5	0	0	0	3	4	4	
2028	6	7	3	5	0	0	0	2	4	4	
2029	6	7	3	6	0	0	0	2	4	4	
2035	6	7	4	5	0	0	0	11	4	4	
2036	6	7	4	6	0	0	0	21	4	4	
2037	6	7	4	7	0	0	0	1	4	4	
2273	7	5	3	5	0	0	0	1	4	4	
2280	7	5	4	5	0	0	0	5	4	4	
2315	7	6	2	5	0	0	0	1	4	4	
2322	7	6	3	5	0	0	0	1	4	4	
2327	7	6	4	3	0	0	1	0	4	4	
2329	7	6	4	5	0	0	0	27	4	4	
2330	7	6	4	6	0	0	0	21	4	4	
2378	7	7	4	5	0	0	0	2	4	4	
2379	7	7	4	6	0	0	0	8	4	4	

表 A2 经ER融合后所得诊断证据
Table A2 The combined diagnosis evidence by ER

编号 q^{th}	融合诊断证据 (训练W)					融合诊断证据 (初始W)				
	$p_{1,e(4)}^q$	$p_{2,e(4)}^q$	$p_{3,e(4)}^q$	$p_{4,e(4)}^q$	$p_{\Theta,e(4)}^q$	$p_{1,e(4)}^q$	$p_{2,e(4)}^q$	$p_{3,e(4)}^q$	$p_{4,e(4)}^q$	$p_{\Theta,e(4)}^q$
1	1	0	0	0	0	1	0	0	0	0
2	1	0	0	0	0	1	0	0	0	0
3	1	0	0	0	0	1	0	0	0	0
8	1	0	0	0	0	0.99	0	0	0.01	0
9	0.98	0	0	0.02	0	0.99	0	0	0.01	0
16	0.99	0	0	0.01	0	0.99	0	0	0.01	0
100	1	0	0	0	0	0.99	0	0	0	0
197	1	0	0	0	0	1	0	0	0	0
344	1	0	0	0	0	1	0	0	0	0
345	0.99	0.01	0	0	0	0.99	0.01	0	0	0
579	0.07	0.93	0	0	0	0	0.86	0.12	0.02	0
580	0.05	0.7	0.04	0.2	0	0.01	0.76	0.15	0.09	0
688	1	0	0	0	0	0.99	0	0	0	0
873	0	0.88	0.11	0.01	0	0	0.88	0.1	0.02	0
880	0	0.07	0.93	0	0	0	0.37	0.6	0.03	0
922	0.01	0.9	0.09	0	0	0	0.81	0.16	0.03	0
929	0	0.04	0.96	0	0	0	0.27	0.7	0.03	0
1031	0.99	0	0	0	0	0.99	0.01	0	0	0
1167	0.04	0.64	0.07	0.25	0	0.01	0.84	0.09	0.07	0
1214	0.01	0.29	0.7	0	0	0	0.66	0.34	0	0
1216	0	0.84	0.15	0.01	0	0	0.88	0.1	0.02	0
1221	0	0.05	0.95	0	0	0	0.13	0.87	0	0
1264	0	0.56	0.44	0	0	0	0.66	0.34	0.01	0
1265	0	0.82	0.17	0	0	0	0.82	0.16	0.02	0
1266	0	0.58	0.18	0.25	0	0	0.72	0.2	0.08	0
1270	0	0.04	0.96	0	0	0	0.09	0.91	0	0
1271	0	0.07	0.93	0	0	0	0.13	0.86	0	0
1272	0	0.08	0.92	0	0	0	0.28	0.69	0.02	0
1273	0	0.08	0.89	0.03	0	0	0.19	0.74	0.07	0
1274	0	0.07	0.92	0.01	0	0	0.14	0.85	0.02	0
1314	0	0.82	0.17	0	0	0	0.65	0.22	0.13	0
1461	0	0.96	0.02	0.02	0	0	0.69	0.22	0.09	0
1496	0.07	0.41	0.02	0.5	0	0.01	0.13	0.29	0.57	0
1504	0.03	0.19	0.35	0.42	0	0.01	0.07	0.39	0.53	0
1509	0.05	0.31	0.27	0.36	0	0.01	0.34	0.47	0.18	0
1510	0.07	0.42	0.02	0.5	0	0.01	0.51	0.24	0.24	0
1538	0.01	0.2	0.05	0.75	0	0	0.26	0.23	0.51	0
1558	0	0.34	0.63	0.03	0	0	0.4	0.53	0.06	0
1559	0	0.75	0.19	0.07	0	0	0.61	0.29	0.11	0
1580	0.08	0	0.01	0.91	0	0.01	0.15	0.24	0.59	0
1581	0.06	0	0.02	0.92	0	0.01	0.05	0.17	0.77	0
1587	0.01	0	0.02	0.97	0	0	0.2	0.32	0.48	0
1588	0.01	0	0.06	0.93	0	0	0.08	0.24	0.68	0
1592	0.01	0	0.98	0.01	0	0	0.04	0.82	0.13	0
1593	0	0.03	0.94	0.03	0	0	0.06	0.75	0.19	0
1594	0	0.09	0.51	0.4	0	0	0.15	0.53	0.32	0
1595	0	0.01	0.2	0.79	0	0	0.06	0.44	0.5	0
1599	0.01	0	0.98	0.01	0	0	0.04	0.92	0.04	0
1600	0	0.01	0.96	0.03	0	0	0.06	0.87	0.07	0
1601	0	0	0.94	0.06	0	0	0.16	0.69	0.14	0
1606	0.01	0	0.98	0.01	0	0	0.21	0.74	0.05	0
1607	0	0.04	0.93	0.03	0	0	0.3	0.64	0.06	0
1608	0	0.17	0.48	0.35	0	0	0.5	0.4	0.11	0
1609	0	0.02	0.2	0.78	0	0	0.34	0.42	0.24	0
1610	0	0.02	0.72	0.26	0	0	0.3	0.6	0.1	0
1613	0	0	1	0	0	0	0.02	0.97	0.02	0

编号 q^{th}	融合诊断证据 (训练W)					融合诊断证据 (初始W)				
	$p_{1,e(4)}^q$	$p_{2,e(4)}^q$	$p_{3,e(4)}^q$	$p_{4,e(4)}^q$	$p_{\Theta,e(4)}^q$	$p_{1,e(4)}^q$	$p_{2,e(4)}^q$	$p_{3,e(4)}^q$	$p_{4,e(4)}^q$	$p_{\Theta,e(4)}^q$
1614	0	0.01	0.99	0	0	0	0.03	0.95	0.02	0
1615	0	0.01	0.99	0	0	0	0.08	0.86	0.06	0
1616	0	0.01	0.96	0.04	0	0	0.04	0.84	0.12	0
1617	0	0.01	0.98	0.01	0	0	0.03	0.93	0.04	0
1629	0.08	0	0.01	0.91	0	0.01	0.03	0.14	0.82	0
1630	0.06	0	0.02	0.92	0	0.01	0	0.09	0.91	0
1636	0.01	0	0.02	0.97	0	0	0.05	0.21	0.75	0
1637	0.01	0	0.06	0.93	0	0	0	0.13	0.87	0
1640	0.05	0.02	0.49	0.44	0	0.08	0	0.39	0.52	0
1641	0.01	0	0.98	0.01	0	0	0	0.71	0.29	0
1642	0	0.03	0.93	0.04	0	0	0	0.61	0.39	0
1643	0	0.05	0.5	0.45	0	0	0.04	0.39	0.57	0
1644	0	0.01	0.2	0.79	0	0	0	0.27	0.72	0
1648	0.01	0	0.98	0.01	0	0	0	0.87	0.13	0
1649	0	0.01	0.96	0.03	0	0	0	0.81	0.19	0
1650	0	0	0.94	0.06	0	0	0.05	0.61	0.34	0
1651	0	0	0.7	0.3	0	0	0	0.49	0.51	0
1654	0.05	0.1	0.47	0.38	0	0.1	0.19	0.43	0.28	0
1655	0.01	0	0.98	0.01	0	0	0.1	0.75	0.15	0
1656	0	0.03	0.93	0.04	0	0	0.14	0.65	0.2	0
1657	0	0.13	0.48	0.4	0	0	0.27	0.41	0.32	0
1664	0	0.01	0.99	0	0	0	0.03	0.81	0.16	0
1678	0.02	0	0	0.97	0	0.01	0.02	0.05	0.92	0
1679	0.02	0	0.01	0.97	0	0	0	0.03	0.96	0
1685	0	0	0.01	0.99	0	0	0.03	0.08	0.88	0
1686	0	0	0.02	0.98	0	0	0	0.05	0.95	0
1692	0	0	0.01	0.99	0	0	0.03	0.2	0.77	0
1693	0	0	0.03	0.97	0	0	0	0.12	0.87	0
1811	0	0.09	0.89	0.01	0	0	0.25	0.6	0.14	0
1923	0.07	0	0	0.92	0	0.02	0.16	0.11	0.72	0
1930	0.01	0	0.01	0.98	0	0	0.22	0.15	0.63	0
1938	0	0.01	0.14	0.85	0	0	0.07	0.25	0.68	0
1972	0.07	0	0	0.92	0	0.01	0.03	0.06	0.91	0
1973	0.06	0	0.02	0.93	0	0.01	0	0.03	0.96	0
1979	0.01	0	0.01	0.98	0	0	0.04	0.08	0.87	0
1984	0.01	0	0.93	0.06	0	0	0	0.52	0.48	0
1986	0	0.02	0.07	0.91	0	0	0.04	0.21	0.75	0
1987	0	0.01	0.14	0.86	0	0	0	0.13	0.86	0
2021	0.02	0	0	0.98	0	0.01	0.02	0.01	0.96	0
2028	0	0	0.01	0.99	0	0	0.03	0.02	0.95	0
2029	0	0	0.01	0.98	0	0	0	0.01	0.99	0
2035	0	0	0.01	0.99	0	0	0.03	0.09	0.88	0
2036	0	0	0.02	0.98	0	0	0	0.05	0.95	0
2037	0	0	0.08	0.92	0	0	0	0.14	0.86	0
2273	0	0	0.01	0.99	0	0	0.13	0.09	0.78	0
2280	0	0	0.02	0.98	0	0	0.13	0.22	0.66	0
2315	0.02	0	0	0.97	0	0.01	0.02	0.03	0.95	0
2322	0	0	0.01	0.99	0	0	0.02	0.04	0.93	0
2327	0	0	0.42	0.58	0	0	0	0.35	0.65	0
2329	0	0	0.02	0.98	0	0	0.02	0.12	0.86	0
2330	0	0	0.03	0.97	0	0	0	0.07	0.93	0
2378	0	0	0.01	0.99	0	0	0.02	0.05	0.94	0
2379	0	0	0.01	0.99	0	0	0	0.03	0.97	0