

基于分层式证据推理的信息融合故障诊断方法

徐晓滨¹, 叶梓发¹, 徐晓健^{1†}, 侯平智^{1,2}, 王琪冰³, 茹晓英³

(1. 杭州电子科技大学 自动化学院, 浙江 杭州 310018; 2. 杭州言实科技有限公司, 浙江 杭州 310018;

3. 森赫电梯股份有限公司, 浙江 湖州 313013)

摘要: 针对基于信息融合的故障诊断方法中, 诊断证据的精细化获取问题和在线诊断信息量受限问题, 提出分层式的证据推理(ER)诊断方法. 在诊断证据获取过程中, 给出故障特征参考值投点方法, 按比例求取特征样本点对相邻参考值的相似度, 生成点值型参考证据矩阵(REM)和在线故障特征样本的诊断证据, 实现了诊断信息的精细化提取; 在证据融合过程中, 设计分层式ER融合模型. 第1层融合中利用 k -NN算法找到在线样本的近邻历史样本, 然后利用ER规则实现在线样本与近邻历史样本对应证据的融合. 在第2层融合中, 将多个特征源提供的第1层融合结果再次融合, 并根据两层融合所获证据进行故障决策; 此外, 在分层融合模型中, 根据证据之间的欧氏距离构造目标函数及相应的证据重要性权重优化方法. 最后, 在多功能电机转子试验台上实施了故障诊断实验, 与已有单层ER模型诊断结果进行比较, 说明所提方法通过提升诊断证据的精确性、增加历史样本扩充诊断信息量, 能够有效提升确诊率.

关键词: 故障诊断; 信息融合; 证据推理; k -NN算法; 分层式证据推理

引用格式: 徐晓滨, 叶梓发, 徐晓健, 等. 基于分层式证据推理的信息融合故障诊断方法. 控制理论与应用, 2020, 37(8): 1681 – 1692

DOI: 10.7641/CTA.2020.90951

Information fusion-based fault diagnosis method via hierarchical evidence reasoning

XU Xiao-bin¹, YE Zi-fa¹, XU Xiao-jian^{1†}, HOU Ping-zhi^{1,2}, WANG Qi-bing³, RU Xiao-ying³

(1. School of Automation, Hangzhou Dianzi University, Hangzhou Zhejiang 310018, China;

2. Hangzhou YanShi S&T Co., Ltd, Hangzhou Zhejiang 310018, China;

3. SRH Elevator Co., Ltd, Huzhou Zhejiang 313013, China)

Abstract: In the framework of information fusion, this paper presents a hierarchical evidence reasoning (ER)-based fusion method to deal with accurate acquirement problem of diagnosis evidence and the information limitation problem in online diagnosis. In the process of diagnosis evidence acquirement, the casting strategy using reference values of fault features is proposed to proportionally calculate the similarity degree between feature sample and its neighboring reference values. In this way, the reference evidence matrix (REM) with the form of point values can be obtained and then the accurate diagnosis evidence of online fault feature sample can be generated by the REM. In the process of evidence fusion, the hierarchical ER fusion model is designed which includes two-level fusion operations. In the first level operation, k -NN algorithm is used to search for the k historical samples close to the online sample and then ER rule is used to fuse the $k+1$ pieces of diagnosis evidence of k historical samples and the online sample. In the second level operation, the multiple first level fusion results coming from different features can be fused again. Thus the diagnosis decision can be made according to the second level fusion results. Furthermore, the objective fusion is constructed based on evidential Euclidean distance to optimize the importance weights of evidence. Final, some diagnosis experiments on a rotor test bed are conducted to compare the proposed hierarchical ER fusion method with the previous single level ER fusion method. The experimental results show that the new method can effectively promote diagnosis rate by enhancing the evidential accuracy and adding historical sample for information expansion.

Key words: fault diagnosis; information fusion; evidence reasoning (ER); k -NN algorithm; hierarchical ER

Citation: XU Xiaobin, YE Zifa, XU Xiaojian, et al. Information fusion-based fault diagnosis method via hierarchical evidence reasoning. *Control Theory & Applications*, 2020, 37(8): 1681 – 1692

收稿日期: 2019-11-15; 录用日期: 2020-04-30.

†通信作者. E-mail: xxj03@hdu.edu.cn; Tel.: +86 15658803375.

本文责任编辑: 周杰.

NSFC-浙江两化融合联合基金项目(U1709215), 国家自然科学基金项目(61903108), 浙江省重点研发计划项目(2019C03104, 2018C04020, 2018C01031)资助.

Supported by the NSFC-Zhejiang Joint Fund for the Integration of Industrialization and Informatization (U1709215), the National Natural Science Foundation of China (61903108) and the Science & Technology Project of Zhejiang Province (2019C03104, 2018C04020, 2018C01031).

1 引言

在工业生产中,如何提高设备运行的安全性和可靠性是一个至关重要的问题.采用多传感系统对关键设备进行状态监测,并对所获故障特征信息进行综合分析,进而研发在线故障检测与诊断新技术,是保证设备安全高效运行的重要途径.通常来说,同一种故障特征的变化可由不同种类的故障所引起,反之,同一种故障变化可以在多种故障特征上得以反映^[1].所以需要多个信息源(传感源)提供的特征信息进行综合,从而得到比任何一个单一信息源更为可靠和准确的故障诊断结果.但是,同时需要考虑监测环境噪声、传感器自身性能差异和安装调试等因素,会使得所获故障特征信号表现出随机性、非平稳、不完备等不确定性,从而对综合诊断结果的准确性造成影响.

多源信息融合技术非常契合解决上述信息综合处理中的不确定性问题,它能够不同时间域、不同空间域、各种途径获得多类不确定性信息,在数据层、特征层和决策层上进行综合处理利用,以至得到一个更准确、更客观的故障决策结果^[1-3].本质上,故障诊断可以看作是多元不确定信息融合中的模式分类决策问题.由此可见,故障决策问题中的各种不确定性,都可以通过信息融合范畴内的各种理论或方法进行解析,并推理得到故障模式分类结果.信息融合的方法一般包含贝叶斯理论、Dempster-Shafer (DS)证据理论,以及神经网络、模糊集理论和专家系统等人工智能领域内的方法^[4-6].其中,基于DS证据理论的“决策级”融合方法,利用Dempster组合规则将各种故障特征提供的“诊断证据(特征支持各个故障发生的一个信度分布函数)”进行综合处理,通过“证据的融合”实现了对不同诊断证据获取方法的综合.因而DS证据理论可以提供综合性的策略解决多元不确定环境下的故障诊断问题,并且在机械、化工、电子等高端装备的状态监测与故障诊断中得到了较为广泛的应用^[3,7-8].

在证据理论框架下,新近被提出的证据推理(evidence reasoning, ER)规则是对传统Dempster组合规则的扩展^[9-10],它明确区分了证据重要性和可靠性的概念^[11].证据重要性权重反映证据与其他证据融合时的相对重要性;可靠性因子反映了单一特征及其证据给出正确分类结果的能力.Dempster规则将可靠性折扣后的剩余信度分配给辨识框架本身,而ER规则将剩余信度分配给辨识框架的幂集,这确保了证据的特异性没有发生改变,从而实现了一个广义的概率推理过程.最近,一些研究人员将ER规则应用于故障诊断中,文献[12]给出了一种基于ER规则的故障诊断方法.它使用故障特征训练样本区间投点和似然函数归一化的方法^[13],求取各信息源的参考证据矩阵(reference evidence matrix, REM)和测试样本的诊断证据;从传感

器误差以及故障特征对各故障模式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,并通过旋转机械故障诊断实例说明所提方法的有效性^[12].

为了提升ER融合模型解决故障诊断与决策问题的适应性与精确性,本文在前人研究的基础上进一步考虑以下问题:1) 诊断证据的精细化获取问题:文献[12]中区间型的REM对于特征信息描述较为粗略,导致从故障特征中获取的诊断证据不够准确;2) 在线诊断时可用信息量受限问题:由于故障的变化是个连续的过程,每次诊断一般要在传感器采样周期内完成,所以用于诊断的故障特征信息只能来自于该采样周期,所以信息量有限,从而较难反映故障状态在连续采样周期内的动态变化.在此情况下,若能加入与当前特征相似的历史特征样本充实诊断信息,则有望提升融合诊断的精准性.

为了解决以上两个问题,本文提出分层式ER模型来增进信息融合故障诊断的精准度.具体的,在证据获取步骤中,给出故障特征参考值投点方法,按比例求取训练样本点对相邻参考值的相似度,并构建点值型REM,它能更加精细化地描述诊断信息,从而有效提升所获诊断证据的精准度;在证据融合步骤中,设计分层式ER融合模型.第1层融合中利用k-NN算法找到在线测试特征样本的近邻历史样本(无标签),然后实现在线测试样本与近邻历史样本对应证据的融合.在第2层融合中,将多个特征源(传感源)提供的第一层融合结果进行再次融合,并根据两层融合所获证据进行故障决策.在双层融合模型中,根据证据之间的欧氏距离构造目标函数及相应的重要性权重优化方法.最后,通过与文献[12]中单层ER模型诊断结果的比较,说明了所提新方法通过提升诊断证据的精确性、利用历史样本增加诊断的信息量等策略,能够有效提升故障诊断(识别)的精准度.

2 证据推理(ER)规则

定义辨识框架 $\Theta = \{D_1, D_2, \dots, D_N\}$,其中的 D 是需要研究的命题,且各个命题之间是两两互斥的,在故障诊断问题中, D 即表示不同的故障模式. Θ 的幂集记为 $P(\Theta)$ 或 2^Θ .ER规则中,从信息源中获取的证据被表示为

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

其中数对 $(\theta, p_{\theta,j})$ 表示证据 e_j 支持 θ 的信度为 $p_{\theta,j}$,命题 θ 可取幂集 $P(\Theta)$ 中的任一元素,也就是辨识框架 Θ 中的任意一个元素(命题)或者元素组成的任何子集.

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 .其中 r_j 表示证据 e_j 的信息源能够对给定元

素或元素子集提供精确信度评估的能力, w_j 定义了 e_j 相较于其它证据的相对重要性, 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, 信息源的不同决定了各自证据的重要性权重也不同. 由此可知 r_j 和 w_j 的物理意义完全不同, 前者单纯依赖于信息源的固有可靠性, 而后者需要根据参与融合的信息源的不同来确定, 带有主观性.

带有可靠性因子 r_j 和重要性权重 w_j 的证据定义如下^[11]:

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

其中信度 $\tilde{m}_{\theta,j}$ 表示含有可靠性因子和重要性权重的 e_j 对 θ 的支持程度:

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

其中: $m_{\theta,j} = w_j p_{\theta,j}$, $c_{rw,j} = \frac{1}{1 + w_j - r_j}$ 是归一化因子, 那么当 $\sum_{\theta \subseteq \Theta} p_{\theta,j} = 1$, 则有

$$\sum_{\theta \subseteq \Theta} \tilde{m}_{\theta,j} + \tilde{m}_{P(\Theta),j} = 1.$$

ER规则中定义了可靠性因子折扣后的剩余信度 $(1 - r_j)$, 其表示了证据的不可靠程度, 并将它赋予幂集 $P(\Theta)$, 即该信度可能支持全集 Θ 及其任何子集. 这种做法保证了 e_j 和 m_j 具有相同的概率特性, 也就是对于各个 θ 的信度赋值的相对比率是不变的, 没有改变信度分布的相对比率结构.

对于两个信息源提供的相互独立的证据 e_1 和 e_2 , 利用ER融合规则对它们进行融合, 得到 e_1 和 e_2 联合支持命题 θ 的信度函数 $p_{\theta,e(2)}$

$$e(2) = \{(\theta, p_{\theta,e(2)}) | \forall \theta \subseteq \Theta, \sum_{\theta \subseteq \Theta} p_{\theta,e(2)} = 1\}, \quad (4a)$$

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

$$\hat{m}_{\theta,e(2)} = ((1 - r_2)m_{\theta,1} + (1 - r_1)m_{\theta,2}) + \sum_{B \cap C = \theta} m_{B,1} m_{C,2}, \quad \forall \theta \subseteq \Theta. \quad (4c)$$

由上文可知, ER规则首先在证据中引入可靠性因子 r_j 和重要性权重 w_j , 从而得到了含有可靠性和重要性权重的信度分布函数, 接着将两个独立的信度分布函数利用ER规则进行融合, 从而获得两个独立证据联合支持辨识框架中某个命题的程度.

对于 n 个信息源提供的 n 组相互独立的证据 $\{e_1, e_2, \dots, e_n\}$, 则可将式(4b)扩展为多证据的ER融合形式, 获得融合后的证据为

$$e(n) = \{(\theta, p_{\theta,e(n)}) | \forall \theta \subseteq \Theta, \sum_{\theta \subseteq \Theta} p_{\theta,e(n)} = 1\}, \quad (5a)$$

$$p_{\theta,e(n)} = \begin{cases} 0, & \theta = \emptyset, \\ \frac{\hat{m}_{\theta,e(n)}}{\sum_{A \subseteq \Theta} \hat{m}_{A,e(n)}}, & \theta \neq \emptyset, \end{cases} \quad (5b)$$

式(5b)中的 $\hat{m}_{\theta,e(n)}$ 是由ER规则递归操作后获得^[11],

$$\hat{m}_{\theta,e(j)} = ((1 - r_j)m_{\theta,e(j-1)} + m_{P(\Theta),e(j-1)}m_{\theta,j}) + \sum_{B \cap C = \theta} m_{B,e(j-1)}m_{C,j}, \quad \theta \subseteq \Theta. \quad (6a)$$

式(6a)中 $m_{\theta,e(j-1)}$ 与 $m_{P(\Theta),e(j-1)}$ ($j = 1, 2, \dots, n$) 分别由式(6b)–(6c)得出:

$$m_{\theta,e(j-1)} = [m_1 \oplus \dots \oplus m_{j-1}](\theta) = \begin{cases} 0, & \theta = \emptyset, \\ \frac{\hat{m}_{\theta,e(j-1)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,e(j-1)} + \hat{m}_{P(\Theta),e(j-1)}}, & \theta \neq \emptyset, \end{cases} \quad (6b)$$

$$\hat{m}_{P(\Theta),e(j-1)} = (1 - r_{j-1})m_{P(\Theta),e(j-2)}. \quad (6c)$$

式(6b)中 m_j 表示第 j 个待融合的证据, 可由式(2)计算得到. 融合迭代计算过程中存在

$$\sum_{\theta \subseteq \Theta} m_{\theta,e(j)} + m_{P(\Theta),e(j)} = 1, \quad j = 1, 2, \dots, n.$$

3 基于ER规则的分层式诊断证据融合与故障决策

在第2节ER融合规则的基础上, 本节为了解决诊断证据的精细化获取问题和在线诊断时可用信息量受限问题, 进一步研究了点值型参考证据矩阵获取方法, 这是获取在线测试样本对应证据的基础, 然后给出了在线样本和近邻样本证据的融合方法. 具体内容在以下小节中给予详细介绍.

3.1 点值型参考证据矩阵(REM)的构造方法

设故障集合 $\Theta = \{D_1, \dots, D_n, \dots, D_N\}$, D_n 代表故障集合 Θ 中的第 n 个故障, $n = 1, 2, \dots, N$, N 为故障模式的个数. 设 f_i 是能够反映故障集合 Θ 中每个故障 D_i 的故障特征变量, 该特征变量的取值由相应传感器测量范围决定.

设训练样本数据集

$$S = \{[f_i(t), Y(t)] | f_i(t) \in S_{f_i}, Y(t) \in \Theta, t = 1, 2, \dots, T_S, i = 1, 2, \dots, M\},$$

其中: $T_S \leq T$, T_S 为训练样本集个数, T 为样本总数, S_{f_i} 是 f_i 的值域, M 为故障特征变量总数, 其中 Y 是对应于特征变量 f_i 的故障模式. 这里需要构建样本对 (f_i, Y) 的投点统计表, 将特征变量 f_i 和故障模式 Y 之间的映射关系转变成 f_i 的参考值集合 $A_i = \{A_i^j | j = 1, \dots, J_i\}$ 与 Y 的参考值集合 $\Theta = \{D_n | n = 1, \dots, N\}$ 之间的对应关系, J_i 为 f_i 的参考值个数. 对于一个特

征变量 f_i , 它关于参考值 A_i 的相似度分布为^[14]

$$S_I(f_i(t)) = \{(A_i^j, \alpha_{i,j}) | j = 1, \dots, J_i, i = 1, \dots, M\}, \quad (7)$$

其中:

$$\alpha_{i,j} = \frac{A_i^{j+1} - f_i(t)}{A_i^{j+1} - A_i^j}, \alpha_{i,j+1} = 1 - \alpha_{i,j},$$

$$A_i^j \leq f_i(t) \leq A_i^{j+1}, \alpha_{i,j'} = 0,$$

$$j' = 1, \dots, J_i, j' \neq j, j + 1.$$

$\alpha_{i,j}$ 表示输入值 $f_i(t)$ 匹配参考值 A_i^j 的相似度.

将训练样本集 S 中的所有样本经由上述方法进行投点统计, 表1中给出了反映特征变量参考值和故障模式之间关系的投点统计表, 其中 $a_{n,j}$ 表示特征变量 $f_i(t)$ 匹配 A_i^j 并且故障模式 $Y(t)$ 为 D_n 的所有样本对 $(f_i(t), Y(t))$ 的相似度和; $\delta_n = \sum_{j=1}^{J_i} a_{n,j}$ 表示所有故障模式为 D_n 的样本对的相似度和; $\eta_j = \sum_{n=1}^N a_{n,j}$ 表示所有 $f_i(t)$ 匹配 A_i^j 的样本对的相似度和, 显然有 $\sum_{n=1}^N \delta_n = \sum_{j=1}^{J_i} \eta_j = T_S$.

表1 样本对 $(f_i(t), Y(t))$ 对参考值投点的统计表

Table 1 Casting matrix of sample pair $(f_i(t), Y(t))$ for the reference values

Y	f_i					总计
	A_i^1	...	A_i^j	...	$A_i^{J_i}$	
D_1	$a_{1,1}$...	$a_{1,j}$...	a_{1,J_i}	δ_1
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
D_n	$a_{n,1}$...	$a_{n,j}$...	a_{n,J_i}	δ_n
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
D_N	$a_{N,1}$...	$a_{N,j}$...	a_{N,J_i}	δ_N
总计	η_1	...	η_j	...	η_{J_i}	T_S

从表1中的每一行可得当 Y 取值为 D_n 时, f_i 取值为 A_i^j 的似然函数 $c_{n,j}$ 如下:

$$c_{n,j} = p(A_i^j | D_n) = \frac{a_{n,j}}{\delta_n}, \quad (8)$$

接着对似然函数 $c_{n,j}$ 进行归一化, 可以生成参考值 A_i^j 所对应的关于 D_1, D_2, \dots, D_N 的证据 e_i^j (表2), 那么 $f_i(t)$ 取 A_i^j 时, $Y(t)$ 为 D_n 的信度为

$$\beta_{n,j}^i = \frac{c_{n,j}}{\sum_{k=1}^N c_{k,j}}. \quad (9)$$

归一化后有 $\sum_{n=1}^N \beta_{n,j}^i = 1$, 则可获得参考值 A_i^j 对应的证据为 $e_i^j = \{(D_n, \beta_{n,j}^i) | n = 1, \dots, N\}$, 可简化为 e_i^j

$= [\beta_{1,j}^i, \beta_{2,j}^i, \dots, \beta_{N,j}^i]$. 实际上, 表2所示的点值型参考证据矩阵描述了由第 i 个信息源历史数据构造的证据模型, 其以信度形式表示了特征变量 f_i 和故障模式 Y 之间的映射关系, 亦即当 $f_i = A_i^j$ 时, 输出 Y 取值为 D_n 的信度(概率)是 $\beta_{n,j}^i$. 文献[12]中是将样本投掷到选定的多个参考区间中的某一个, 而本文采用的参考值投点是按比例求取样本点对相邻两个参考值的相似度. 前者是一种“绝对的”和“离散的”投点计数方式, 而后者是一种“相对的”和“连续的”投点计数方式, 更能细致刻画样本与参考量之间的关联关系.

表2 特征变量 f_i 的点值型参考证据矩阵(REM)

Table 2 The reference evidence matrix (REM) with the form of point values of input f_i

Y	e_i^1	...	e_i^j	...	$e_i^{J_i}$
	A_i^1	...	A_i^j	...	$A_i^{J_i}$
D_1	$\beta_{1,1}^i$...	$\beta_{1,j}^i$...	β_{1,J_i}^i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
D_n	$\beta_{n,1}^i$...	$\beta_{n,j}^i$...	β_{n,J_i}^i
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
D_N	$\beta_{N,1}^i$...	$\beta_{N,j}^i$...	β_{N,J_i}^i

3.2 基于 k -近邻的历史样本扩充方法

k -近邻(k -nearest neighbor, k -NN)算法是一种常用的机器学习算法^[15-16], 其基本思路是: 一个样本的属性由该样本在特征空间中 K 个最邻近样本所决定, 通过某种距离度量(例如欧氏距离)找出特征空间中与其最邻近的 K 个样本, 然后基于这 K 个最近邻样本信息来进行决策. 在本文的分层式ER模型中, 可以利用 k -NN算法从训练集 S 中获取与在线样本相似的历史样本参与融合推理过程.

对于多输入特征变量下的故障诊断模型, 各特征变量由于物理意义或信号采集方法等方面存在差异, 通常具有不同的量纲和数量级. 如果某一个特征变量的值域范围非常大, 那么 k -NN算法在进行距离度量时就主要取决于这个特征, 从而可能得到与实际情况不相符的近邻检测结果. 因此, 为了确保各个信息源提供的故障分类信息都能充分发挥各自的作用, 在使用 k -NN算法确定近邻历史样本之前, 需要对原始特征变量数据进行标准化(归一化)处理.

数据的标准化是将各特征变量数据按比例缩放, 消除不同单位和量纲对数据的影响, 便于不同单位或量级的指标能够进行比较. 这里运用最为常用的 min-max 标准化方法, 具体为

$$M f_i(t) = \frac{f_i(t) - \min_t(f_i(t))}{\max_t(f_i(t)) - \min_t(f_i(t))}, \quad (10)$$

其中 $t \in \{1, 2, \dots, T_s\}$.

对原始数据进行标准化之后, 接下来就可通过 k -NN 算法获取在线样本的 K 个近邻历史样本. 若将当前的在线样本记为 $F'(t) = [f_1(t) f_2(t) \dots f_M(t)]$, 则可求得它与历史样本 $F(\tau) = [f_1(\tau) f_2(\tau) \dots f_M(\tau)]$ 的欧氏距离为

$$d_\tau(F', F) = \sqrt{\sum_{i=1}^M (M f_i(t) - M f_i(\tau))^2}, \quad (11)$$

其中 $\tau = 1, \dots, T_s$, 将计算出的 d_τ 按照从小到大的顺序进行排列, 从中选出距离最小的 K 个历史样本, 记为 $F_k = \{[f_1^k f_2^k \dots f_M^k] | k = 1, 2, \dots, K\}$, 显然 K 取值越大, 在第 1 层融合中的计算量就越大.

3.3 基于 REM 的在线测试样本证据获取以及分层式融合

由第 3.2 节的 k -NN 算法从训练样本集中获得了在线样本的 K 个近邻历史样本, 接下来获取在线样本和 K 个近邻历史样本的证据. 对于某信息源提供的特征样本 $f_i(t)$ (在线样本或历史样本), 它的取值必然属于某个特定的参考值区间 $[A_i^j, A_i^{j+1}]$, 因此它必定激活表 2 (REM) 中的两条相邻证据 e_i^j, e_i^{j+1} , 那么, $f_i(t)$ 激活的证据 e_i 可以表示为 e_i^j 与 e_i^{j+1} 的加权和:

$$e_i = \{(D_n, p_{n,i}), n = 1, \dots, N\}, \quad (12)$$

$$p_{n,i} = \alpha_{i,j} \beta_{n,j}^i + \alpha_{i,j+1} \beta_{n,j+1}^i, \quad (13)$$

其中 $p_{n,i}$ 表示在线或历史样本对于故障模式 D_n 的支持信度.

对于某个包含 M 个特征的在线样本

$$F'(t) = [f_1(t) f_2(t) \dots f_M(t)],$$

通过式 (12)–(13) 可获得它的 M 条证据 $[e_1^t e_2^t \dots e_M^t]$ 以及 K 个近邻历史样本的激活证据 $[e_1^1 e_2^1 \dots e_M^1], [e_1^2 e_2^2 \dots e_M^2], \dots, [e_1^K e_2^K \dots e_M^K]$. 然后, 对于每个特征变量 f_i , 利用了式 (5)–(6) 将证据 e_i^t 与 $[e_i^1 e_i^2 \dots e_i^K]$ 进行 ER 递推融合, 并得到第 1 层 ER 融合结果

$$e_i(K+1) = \{(D_n, p_{n,e_i(K+1)}) | i = 1, \dots, M, n = 1, \dots, N\}. \quad (14)$$

然后, 将 M 个特征变量的第 1 层融合结果 $e_1(K+1), e_2(K+1), \dots, e_M(K+1)$ 进行第 2 层融合, 获得最终的融合结果 (具体过程见图 1).

$$e(M) = \{(D_n, p_{n,e(M)}) | n = 1, \dots, N\}. \quad (15)$$

基于上式的故障决策规则如下: 最终融合结果中最大信度所指向的故障模式即为在线获取的测试样本对应的故障模式^[1].

因为可靠性较高的证据应具有相对较高的证据权重, 所以设定当前测试样本证据以及近邻历史样本证据 $[e_i^1 e_i^2 \dots e_i^K]$ 的初始重要性权重 w 等于该证据

对应的可靠性因子 r . 下一节将对证据的可靠性因子的计算方法和证据重要性权重等参数的优化方法进行详细介绍. 图 1 中 w_i 为第 i 个特征变量的重要性权重, 用于第 2 层融合; w_i' 和 $w_i^1, w_i^2, \dots, w_i^K$ 依次为第 i 个特征变量第一层融合时, 在线测试样本和 K 个历史样本的重要性权重.

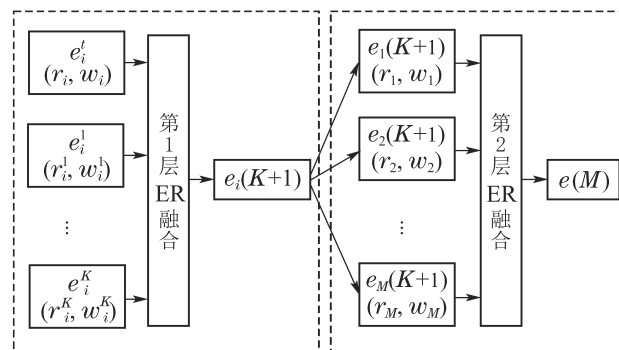


图 1 分层式 ER 融合示意图

Fig. 1 The diagram of fusion model based on hierarchical ER

4 分层式 ER 融合模型中证据可靠性和重要性参数的计算方法

4.1 基于特征变量变化区间的证据可靠性因子获取方法

在分层式 ER 融合模型中, 在线样本证据 e_i^t 的可靠性和近邻历史样本证据 $\{e_i^1, e_i^2, e_i^3\}$ (以 $K=3$ 为例) 的可靠性既有联系又有区别. e_i^t 的可靠性因子 r_i 描述了信息源对给定问题提供正确评估的能力. 在故障模式识别问题中, 特征变量 f_i 可靠性越高, 不同故障模式的特征变量区间之间具有相对小的重叠, 则它越能够准确而独立地识别样本所反映的故障模式. 因此, 特征变量 f_i 的可靠性因子可以定义如下^[17]:

$$r_i = \frac{V_i}{\max_{l,l \in \{1,2,\dots,M\}} (V_l)}, \quad (16)$$

其中 V_i 表示能够直接根据特征变量 f_i 判断为某个故障模式的样本数量, V_i 越大, 那么特征变量 f_i 越可靠. 进一步的由式 (16) 可知, 可以通过与最可靠特征变量相比较而得到其余特征变量的可靠性. 图 2 中给出了一个例子进行说明, 表示了当故障模式个数为 3 时, 如何得到特征变量的可靠性, 其中 L_n 和 R_n 分别为故障模式 $D_n (n = 1, 2, 3)$ 下, 特征变量 f 的最小值和最大值. 从图中可以得到特征变量能够独立诊断出各故障模式的样本数量分别为 v_1, v_2, v_3 , 则有 $V = v_1 + v_2 + v_3$, 而剩余的 $o_1 + o_2$ 个样本处于重叠区间, 由于支持两种故障模式的发生, 所以是含有不确定性的样本.

此外, 历史样本证据 $[e_i^1 e_i^2 e_i^3]$ 与 e_i^t 同样也来自于特征变量 f_i , 是通过和 e_i^t 的相似性比较被确定的, 所以在确定它们的可靠性时, 不仅要考虑特征变量 f_i 本身, 还要考虑它们与 e_i^t 的相似性关系. 因此, 这里根据式

(11)中得到的 $K = 3$ 个历史样本与当前样本的欧氏距离值 d_k , 计算 e_i^k 的相对可靠性为

$$r_i^k = (1 - d_k)r_i, \quad i = 1, \dots, M, \quad k = 1, 2, 3. \quad (17)$$

显然, d_k 越小则相应的历史样本证据的相对可靠性越大, 亦即与 e_i^k 距离越近, 则可靠性越高. 例如, 这里若设定 $d_1 \leq d_2 \leq d_3$, 则 $r_i^1 \geq r_i^2 \geq r_i^3$.




图2 特征变量 f 的样本分布

Fig. 2 The distribution of samples for the feature variable f

4.2 基于遗传算法的参数优化模型与诊断结果评价

分层式ER模型的初始参数包括特征变量参考值 $A_i = \{A_i^j | j = 1, \dots, J_i\}$ 和两层融合(图1)中证据的重要性权重

$$W = \{w_i, w'_i, w_i^k | i = 1, \dots, M, \quad k = 1, 2, 3\}.$$

仅靠初始参数建模的分层ER模型不能准确地给出特征变量 f_i 和故障模式 Y 之间的复杂关系, 所以需要利用训练样本集合 S 对这些参数进行进一步的优化调整, 从而达到提升融合模型精度的目的. 因此, 以误差最小化为目标函数构建参数优化模型

$$\min_P \xi(P) = \sum_{t=1}^{T_s} d_E(e^t(M), \varphi(t)), \quad (18a)$$

$$\text{s.t. } 0 \leq w_i, w'_i, w_i^k \leq 1, \quad i = 1, \dots, M, \quad k = 1, 2, 3, \quad (18b)$$

$$A_i^{j-1} < A_i^j < A_i^{j+1}, \quad j = 2, \dots, J_i - 1, \quad (18c)$$

其中: $\xi(P)$ 表示目标函数,

$$P = \{A_i, W | i = 1, \dots, M, \quad j = 2, \dots, J_i - 1\}$$

表示待优化的参数集合, 设定其他参数 A_i^1 和 $A_i^{J_i}$ 分别为 $\min_{k, k \in S_{f_i}} (f_i(t))$, $\max_{k, k \in S_{f_i}} (f_i(t))$, 即这些值均为固定的边界值. d_E 表示融合结果

$$e^t(M) = (p_{1,e(M)}, p_{2,e(M)}, \dots, p_{N,e(M)})$$

(即式(15)中的信度向量)和参考信度向量 $\varphi(t)$ 之间的距离(一般取欧氏距离即可). 参考信度向量 $\varphi(t)$ 指的

是将绝对信度分配给特征向量 $f(t)$ 指向的实际故障模式 D_n . 例如, 如果 $f(t)$ 的实际故障模式为 D_3 , 那么相应的参考信度向量为 $\varphi(t) = (0, 0, 1, 0, \dots, 0)$.

本文引入遗传算法(genetic algorithm, GA)作为优化引擎, 按照适者生存和优胜劣汰准则, 对初始种群逐代演化产生出更优的近似解. 在每一代, 根据待优化的参数集合中个体的适应度值大小选择个体, 并借助于自然遗传学的遗传算子进行组合交叉和变异操作, 产生出代表新的解集的种群^[18]. 随着种群的迭代优化, 参数集 P 也在不断地变化, 表2所示的参考证据矩阵中的信度也将逐步达到最优.

通过以上优化模型获得的故障诊断结果, 可以构造出如下所示的混淆矩阵, 其中定义第 n 个故障模式的确诊率如下:

$$u_n = \frac{M_{n,n}}{S_n} \times 100\%, \quad n = 1, \dots, N. \quad (19)$$

表3中, $M_{l,s} (l, s = 1, \dots, N)$ 表示真实故障模式为 D_l 而诊断结果为 D_s 的样本数量, 其中混淆矩阵对角线上的元素表示各故障模式被正确诊断的样本个数.

表3 分层式ER模型诊断结果的混淆矩阵

Table 3 The confusion matrix for diagnosis results of hierarchical ER model

		故障诊断结果					总计	确诊率
		D_1	\dots	D_n	\dots	D_N		
故障 模式	D_1	$M_{1,1}$	\dots	$M_{1,n}$	\dots	$M_{1,N}$	S_1	u_1
	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
	D_n	$M_{n,1}$	\dots	$M_{n,n}$	\dots	$M_{n,N}$	S_n	u_n
	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
	D_N	$M_{N,1}$	\dots	$M_{N,n}$	\dots	$M_{N,N}$	S_N	u_N

5 在电机转子故障诊断中的实验验证

5.1 电机转子的故障设置

本文以电机转子故障诊断为例, 验证分层式ER融合模型的有效性. 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加速度信号. 经HG-8902采集模块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, 3].

实验中设置了4种典型故障模式: 正常运行 D_1 , 转子不平衡 D_2 , 转子不对中 D_3 , 基座松动 D_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 $1X \sim 3X$ 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 1500 r/m , 则基频 $1X$ 为 25 Hz , n 倍频 $nX (n = 1, 2, 3)$ 为 $(n \times 25) \text{ Hz}$. 这里, 将频域的 $1X \sim 3X$ 的振动幅值以及时域振动位移作为特征变量 $f_1 \sim f_4$ 进行综合做出决策.

5.2 构造特征变量的参考证据矩阵

首先可确定本实验中的故障辨识框架为 $\Theta = \{D_1, D_2, D_3, D_4\}$. 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 种典型故障模式下, 以时间间隔 $\Delta t = 16 \text{ s}$ 连续采集 $\delta = 800$ 次测量值, 即可获取 3200 个测量样本. 从每种故障模式的 800 组样本中随机选取 500 组构建训练样本

$$S = \{[f_i(t), Y(t)] | f_i(t) \in S_{f_i}, Y(t) \in \Theta, i = 1, 2, 3, 4, t = 1, 2, \dots, T_S, T_S = 2000\},$$

剩余 1200 组样本作为测试集.

根据经验, 设故障特征变量 f_1 初始参考值为

$$A_1 = \{0.0681, 0.1485, 0.1567, 0.1654, 0.1706, 0.1986, 0.2176\};$$

f_2 的参考值为

$$A_2 = \{0.0974, 0.1301, 0.1410, 0.1571, 0.1865, 0.1994, 0.2147\};$$

f_3 的参考值为

$$A_3 = \{0.0446, 0.1179, 0.1383, 0.1699, 0.1829, 0.2096, 0.2718\};$$

f_4 的参考值为

$$A_4 = \{3.6009, 3.9090, 4.0004, 4.2550, 4.3850, 4.8510, 5.2070\}.$$

然后根据第 3.1 节的信息转换技术和似然函数归一化方法可获得这些样本的投点统计表和点值型参考证据矩阵. 可根据第 4.1 节提供的可靠性评估方法计算每个特征变量证据的可靠性因子, 分别为 $r_1 = 0.9591, r_2 = 0.7519, r_3 = 1, r_4 = 0.8464$. 相应的证据重要性权重 $w_i (i = 1, \dots, 4)$ 的初始值被设定 $w'_i = w_i^1 = w_i^2 = w_i^3 = w_i = r_i$.

对于训练样本集 S 中任意一组样本, 可以利用分层式 ER 融合模型辨识出它对应的故障模式. 再根据第 4.2 节所提的目标函数和训练样本, 获取最优参数集合 P . 对于测试样本集中的任意一组样本, 可利用训练后的分层 ER 融合模型判断它的故障模式. 表 4-11 列出了基于最优参数集构造的投点统计表和点值型参考证据矩阵.

表 12 列出了训练后两层融合中各个证据的最优重要性权重(与图 2 中的标识符号对应).

表 4 最优参考值下故障特征变量 $1X$ 的投点统计表

Table 4 The casting result of the fault feature variable $1X$ under the optimal reference value

Y	A_1^1	A_1^2	A_1^3	A_1^4	A_1^5	A_1^6	A_1^7	总计
	0.0681	0.1496	0.1578	0.1606	0.1712	0.1784	0.2176	
D_1	242.7132	252.7409	3.3022	0.7859	0.4578	0	0	500
D_2	0.0137	24.8416	99.7902	291.1126	68.5940	14.1849	1.4630	500
D_3	0	0.2180	7.7480	32.8817	91.0576	295.2753	72.8194	500
D_4	0	0	0	0.0569	3.7887	228.7791	267.3753	500
总计	242.7269	277.8005	110.8404	324.8371	163.8981	538.2393	341.6577	2000

表 5 最优参考值下故障特征变量 $2X$ 的投点统计表

Table 5 The casting result of the fault feature variable $2X$ under the optimal reference value

Y	A_2^1	A_2^2	A_2^3	A_2^4	A_2^5	A_2^6	A_2^7	总计
	0.0974	0.1183	0.1387	0.1483	0.1852	0.2072	0.2147	
D_1	14.7027	102.5603	177.1452	166.8154	37.9605	0.8159	0	500
D_2	0	0	1.0344	224.4351	274.4709	0.0596	0	500
D_3	0	0	0.0000	100.3723	367.7149	31.9128	0	500
D_4	0	0.6183	2.9541	20.9138	244.7471	216.1971	14.5694	500
总计	14.7027	103.1786	181.1338	512.5366	924.8935	248.9854	14.5694	2000

表6 最优参考值下故障特征变量3X的投点统计表

Table 6 The casting result of the fault feature variable 3X under the optimal reference value

Y	A_3^1	A_3^2	A_3^3	A_3^4	A_3^5	A_3^6	A_3^7	总计
	0.0446	0.1160	0.1408	0.1568	0.1966	0.2126	0.2718	
D_1	190.5857	302.6943	6.7200	0	0	0	0	500
D_2	0	0	0	63.3471	413.2856	23.3674	0	500
D_3	0	0.5070	7.9936	161.6330	149.7017	139.4549	40.7098	500
D_4	0	132.2133	315.1440	46.8959	5.7468	0	0	500
总计	190.5857	435.4146	329.8576	271.8759	568.7341	162.8223	40.7098	2000

表7 最优参考值下时域振动位移平均幅值的投点统计表

Table 7 The casting result of the fault feature variable "displacement" under the optimal reference value

Y	A_4^1	A_4^2	A_4^3	A_4^4	A_4^5	A_4^6	A_4^7	总计
	3.6009	3.9163	4.0039	4.2578	4.5305	4.8514	5.2070	
D_1	176.7830	289.7918	33.4252	0	0	0	0	500
D_2	0	0	0.0110	42.7948	421.9660	35.2281	0	500
D_3	0.0231	3.0506	23.7314	134.4703	213.2512	113.1694	12.3040	500
D_4	0	0	0	0.8233	86.8598	388.3121	24.0048	500
总计	176.8061	292.8424	57.1676	178.0884	722.0771	536.7096	36.3088	2000

表8 故障特征1X的点值型参考证据矩阵

Table 8 The REM with the form of point values of fault feature 1X

Y	e_1^1	e_1^2	e_1^3	e_1^4	e_1^5	e_1^6	e_1^7
	A_1^1	A_1^2	A_1^3	A_1^4	A_1^5	A_1^6	A_1^7
D_1	0.9999	0.9098	0.0298	0.0024	0.0028	0	0
D_2	0.0001	0.0894	0.9003	0.8962	0.4185	0.0264	0.0043
D_3	0	0.0008	0.0699	0.1012	0.5556	0.5486	0.2131
D_4	0	0	0	0.0002	0.0231	0.4251	0.7826

表9 故障特征2X的点值型参考证据矩阵

Table 9 The REM with the form of point values of fault feature 2X

Y	e_2^1	e_2^2	e_2^3	e_2^4	e_2^5	e_2^6	e_2^7
	A_2^1	A_2^2	A_2^3	A_2^4	A_2^5	A_2^6	A_2^7
D_1	1	0.9940	0.9780	0.3255	0.0410	0.0033	0
D_2	0	0	0.0057	0.4379	0.2968	0.0002	0
D_3	0	0	0	0.1958	0.3976	0.1282	0
D_4	0	0.0060	0.0163	0.0408	0.2646	0.8683	1

5.3 典型测试样本的融合推理流程展示与结果分析

在获取最优的点值型REM之后, 接下来可利用1200组测试样本对构造的分层式ER融合模型进行

诊断测试, 这里给出了两种典型的测试样本情况, 对融合模型的计算过程及优点进行详细阐述。

情况1 在线测试样本与近邻历史样本指向的实际故障模式不完全一致。

给定测试样本[0.1792 0.1693 0.1834 4.3620] (实际故障模式为 D_3)。根据表8-11可知, 它的特征变量 $f_1 = 0.1792$ 以相似度 $\alpha_{1,6} = 0.9811$ 和 $\alpha_{1,7} = 0.0189$ 分别激活了 e_1^6 和 e_1^7 ; $f_2 = 0.1693$ 以相似度 $\alpha_{2,4} = 0.4308$ 和 $\alpha_{2,5} = 0.5692$ 分别激活了 e_2^4 和 e_2^5 ; $f_3 = 0.1834$ 以相似度 $\alpha_{3,4} = 0.3323$ 和 $\alpha_{3,5} = 0.6677$ 分别激活了 e_3^4 和 e_3^5 ; $f_4 = 4.3620$ 以相似度 $\alpha_{4,4} = 0.6179$ 和 $\alpha_{4,5} = 0.3821$ 分别激活了 e_4^4 和 e_4^5 。根据式(12)按照相似度对相应的参考证据进行加权后获得该测试样本证据, 如表13中所示。

表10 故障特征3X的点值型参考证据矩阵

Table 10 The REM with the form of point values of fault feature 3X

Y	e_3^1	e_3^2	e_3^3	e_3^4	e_3^5	e_3^6	e_3^7
	A_3^1	A_3^2	A_3^3	A_3^4	A_3^5	A_3^6	A_3^7
D_1	1	0.6952	0.0204	0	0	0	0
D_2	0	0	0	0.2330	0.7267	0.1435	0
D_3	0	0.0012	0.0242	0.5945	0.2632	0.8565	1
D_4	0	0.3036	0.9554	0.1725	0.0101	0	0

表 11 时域振动位移平均幅值点值型参考证据矩阵
Table 11 The REM with the form of point values of fault feature “displacement”

Y	e_4^1	e_4^2	e_4^3	e_4^4	e_4^5	e_4^6	e_4^7
	A_4^1	A_4^2	A_4^3	A_4^4	A_4^5	A_4^6	A_4^7
D_1	0.9999	0.9896	0.5847	0	0	0	0
D_2	0	0	0.0002	0.2403	0.5844	0.0656	0
D_3	0.0001	0.0104	0.4151	0.7551	0.2953	0.2109	0.3389
D_4	0	0	0	0.0046	0.1203	0.7235	0.6611

表 12 两层融合中各个诊断证据的最优权重

Table 12 The optimized importance weight of every piece of diagnosis evidence during the hierarchical fusion

i	w_i	w'_i	w_i^1	w_i^2	w_i^3
1	0.9425	0.5472	0.5018	0.3275	0.2995
2	0.7519	0.7473	0.6853	0.4473	0.4090
3	0.9254	0.9841	0.9025	0.5890	0.5386
4	0.8215	0.6316	0.5792	0.3780	0.3457

表 13 测试样本及其近邻历史样本的诊断证据(情况 1)

Table 13 Diagnosis evidence in testing dataset and their nearest neighboring samples (Case 1)

f	D_1	D_2	D_3	D_4	
$f_1(t)$	e_1^t	0	0.0445	0.5294	0.4261
f_1^1	e_1^1	0	0.0262	0.5470	0.4268
f_1^2	e_1^2	0	0.0249	0.5262	0.4489
f_1^3	e_1^3	0.0004	0.0786	0.5495	0.3715
$f_2(t)$	e_2^t	0.1497	0.3676	0.3124	0.1704
f_2^1	e_2^1	0.1668	0.3592	0.3083	0.1656
f_2^2	e_2^2	0.1497	0.3507	0.3205	0.1791
f_2^3	e_2^3	0.1404	0.3461	0.3271	0.1864
$f_3(t)$	e_3^t	0	0.5718	0.3780	0.0502
f_3^1	e_3^1	0	0.5835	0.4089	0.0076
f_3^2	e_3^2	0	0.7176	0.2693	0.0131
f_3^3	e_3^3	0	0.6916	0.2868	0.0216
$f_4(t)$	e_4^t	0	0.3622	0.5869	0.0509
f_4^1	e_4^1	0	0.4308	0.5006	0.0686
f_4^2	e_4^2	0	0.3819	0.5659	0.0522
f_4^3	e_4^3	0	0.4096	0.5288	0.0615

由式(11)找到该测试样本的 $K = 3$ 个近邻历史样本为[0.1786 0.1689 0.2006 4.4087](实际故障

模式为 D_2), [0.1810 0.1711 0.1954 4.3700](实际故障模式为 D_3)和[0.1775 0.1723 0.1938 4.3920](实际故障模式为 D_3). 再次利用式(12)获得测试样本 f_i 的近邻样本 f_i^1, f_i^2, f_i^3 的诊断证据如表 13 中所示.

由式(17)可计算得到 e_i^t 的 3 个近邻证据 e_i^1, e_i^2, e_i^3 的可靠性因子如表 14 所示. 由于近邻程度是从高到低排列的, 所以这里有 $r_i^1 \geq r_i^2 \geq r_i^3$.

表 14 近邻证据的可靠性因子(情况 1)

Table 14 The reliability factors of the evidence activated by nearest neighboring samples (Case 1)

i	r_i^1	r_i^2	r_i^3
1	0.8796	0.5740	0.5249
2	0.6869	0.4500	0.4115
3	0.9171	0.5985	0.5473
4	0.7762	0.5066	0.4632

利用计算得到的证据可靠性因子(表 14)和优化后得到的重要性权重(表 12)对证据进行分层 ER 融合(如图 1 所示流程), 得到第 1 层融合结果为

$$e_1(4) = \{(D_1, 0), (D_2, 0.0112), (D_3, \mathbf{0.6146}), (D_4, 0.3742)\},$$

$$e_2(4) = \{(D_1, 0.1185), (D_2, 0.4121), (D_3, \mathbf{0.3320}), (D_4, 0.1374)\},$$

$$e_3(4) = \{(D_1, 0), (D_2, 0.8008), (D_3, 0.1963), (D_4, 0.0029)\},$$

$$e_4(4) = \{(D_1, 0), (D_2, 0.3424), (D_3, \mathbf{0.6333}), (D_4, 0.0243)\}.$$

可以看出, 特征变量 $f_1(t), f_2(t)$ 和 $f_4(t)$ 对应的第 1 层融合结果中, 信度都在不同程度上更加聚焦于真实故障模式 D_3 . 然后将 $e_1(4), e_2(4), e_3(4)$ 和 $e_4(4)$ 进行第 2 层融合, 得到最终融合结果为 $e(4) = \{(D_1, 0), (D_2, 0.1963), (D_3, \mathbf{0.8023}), (D_4, 0.0014)\}$. D_3 对应最大信度, 因此判断故障模式为 D_3 , 与测试样本的真实故障模式一致.

观察各个近邻历史样本实际故障模式, 它们并不一定都和测试样本的实际故障模式保持一致, 亦即这些历史样本所对应证据的信度分布也与测试样本证据的信度分布有差异. 但是, 它们对测试样本都具有一定的相似性, 所以经证据融合后信度仍然能够聚焦到真实的故障模式. 而使用文献[12]中单层 ER 融合方法得到的结果为 $(D_1, 0), (D_2, 0.5021)$,

$(D_3, 0.4302), (D_4, 0.0677)$, 判断的故障模式为 D_2 , 与真实故障模式不一致. 这说明所提出的分层式ER融合方法, 在提升诊断证据精细化程度的同时, 引入更多的历史样本信息参与融合推理, 最终取得了更好的故障分类效果.

情况 2 在线测试样本与近邻历史样本指向的实际故障模式一致.

给定测试样本 $[0.1621, 0.1682, 0.1903, 4.5045]$ (实际故障模式为 D_2). 利用“情况1”中给出的同样流程, 可获得该测试样本的诊断证据, 如表15中所示. 根据式(11)找到该测试样本的 $K = 3$ 个近邻历史样本为 $[0.1611 \ 0.1655 \ 0.1999 \ 4.5103], [0.1594 \ 0.1721 \ 0.2007 \ 4.5375]$ 和 $[0.1595 \ 0.1660 \ 0.2013 \ 4.4940]$, 它们都指向 D_2 , 相应的诊断证据如表15中所示.

表 15 测试样本及其近邻历史样本的诊断证据(情况2)

Table 15 Diagnosis evidence in testing dataset and their nearest neighboring samples (Case 2)

f		D_1	D_2	D_3	D_4
$f_1(t)$	e_1^t	0	0.8312	0.1677	0.0011
	f_1^1	0.0024	0.8719	0.1243	0.0013
	f_1^2	0.0138	0.8979	0.0883	0.0001
	f_1^3	0.0133	0.8978	0.0888	0.0001
$f_2(t)$	e_2^t	0.1575	0.3730	0.3063	0.1631
	f_2^1	0.1929	0.3721	0.2899	0.1452
	f_2^2	0.1420	0.3468	0.3260	0.1852
	f_2^3	0.1888	0.3701	0.2928	0.1483
$f_3(t)$	e_3^t	0	0.6629	0.3093	0.0277
	f_3^1	0	0.6090	0.3829	0.0081
	f_3^2	0	0.5762	0.4163	0.0075
	f_3^3	0	0.5552	0.4377	0.0071
$f_4(t)$	e_4^t	0	0.5627	0.3169	0.1204
	f_4^1	0	0.5588	0.3295	0.1117
	f_4^2	0	0.5731	0.2935	0.1334
	f_4^3	0	0.5383	0.3569	0.1048

由式(17)可计算得到 e_i^t 的3个近邻证据 e_i^1, e_i^2, e_i^3 的可靠性因子分别见表16.

利用计算得到的证据可靠性(表16)和优化后得到的重要性权重(表4)对证据进行两层ER融合, 得到第1层融合结果为

$$e_1(4) = \{(D_1, 0.0003), (D_2, \mathbf{0.9500}), (D_3, 0.0494), (D_4, 0.0003)\},$$

$$e_2(4) = \{(D_1, 0.1378), (D_2, \mathbf{0.4172}), (D_3, 0.3133), (D_4, 0.1317)\},$$

$$e_3(4) = \{(D_1, 0), (D_2, \mathbf{0.7696}), (D_3, 0.2257), (D_4, 0.0047)\},$$

$$e_4(4) = \{(D_1, 0), (D_2, \mathbf{0.6640}), (D_3, 0.2654), (D_4, 0.0706)\}.$$

表 16 近邻证据的可靠性因子(情况2)

Table 16 Reliability factors of the evidence activated by nearest neighboring samples (Case 2)

i	r_i^1	r_i^2	r_i^3
1	0.6870	0.5783	0.4622
2	0.5368	0.4534	0.3623
3	0.7163	0.6030	0.4819
4	0.6063	0.5104	0.4079

显然, 4个特征的第1层融合结果都将信度聚焦于真实故障模式 D_2 . 然后进行第2层融合得到 $e(4) = \{(D_1, 0), (D_2, \mathbf{0.9876}), (D_3, 0.0124), (D_4, 0)\}$. D_2 对应有最大信度, 因此判断故障模式为 D_2 , 决策正确.

然而使用文献[12]中单层ER融合方法得到相应的结果为 $\{(D_1, 0), (D_2, 0.7057), (D_3, 0.2937), (D_4, 0.0006)\}$, 判断的故障模式为 D_2 . 虽然该方法正确判断了故障模式, 但是计算得到的 D_2 信度远小于分层式ER模型给出的信度赋值, 这说明本文所提出的分层式ER融合方法, 通过引入更多的历史样本信息参与融合推理, 得到对于真实故障模式更加高的信度赋值, 那么给出的决策就更加可靠.

表17-18列出了分层式ER模型对训练样本集和测试样本集融合诊断的结果, 并与文献[12]中单层ER模型进行了对比.

从表17-18中可以看出, 在同样的训练和测试样本下, 相比单层ER模型, 分层式ER模型在总体上都有更高的故障确诊率.

为了获得更可靠的结果反映分层式ER模型的性能, 重复上述实验100次, 每次试验都从总样本中随机生成训练样本2000个和测试样本1200个. 通过统计得到, 在100次随机试验中, 分层式ER模型对于测试样本的平均确诊率为96.6%, 具体对于每种故障模式的平均确诊率如表19所示, 而单层ER模型的平均确诊率为95.1%, 平均确诊率如表20所示. 从此可以看出, 所提方法诊断效果相对稳定, 并且整体上高于单层ER模型.

表 17 训练样本集诊断结果对比(混淆矩阵)

Table 17 Comparison of diagnosis results of training samples (confusion matrix)

	融合故障诊断结果 (分层式ER)					确诊率	融合故障诊断结果 (单层ER)					确诊率	总计
					D ₄						D ₄		
	D ₁	D ₂	D ₃	D ₄			D ₁	D ₂	D ₃	D ₄			
故障模式	D ₁	500	0	0	0	100%	500	0	0	0	100%	500	
	D ₂	0	490	10	0	98%	0	485	10	5	97%	500	
	D ₃	0	1	494	5	98.8%	0	1	473	26	94.6%	500	
	D ₄	0	0	20	480	96%	14	0	10	476	95.2%	500	

表 18 测试样本集诊断结果对比(混淆矩阵)

Table 18 Comparison of diagnosis results of testing samples (confusion matrix)

	融合故障诊断结果 (分层式ER)					确诊率	融合故障诊断结果 (单层ER)					确诊率	总计
					D ₄						D ₄		
	D ₁	D ₂	D ₃	D ₄			D ₁	D ₂	D ₃	D ₄			
故障模式	D ₁	300	0	0	0	100%	300	0	0	0	100%	300	
	D ₂	0	281	19	0	93.7%	8	277	15	0	92.3%	300	
	D ₃	0	4	290	6	96.7%	0	3	280	17	93.3%	300	
	D ₄	0	0	15	285	95%	6	0	18	276	92%	300	

表 19 分层式ER模型测试样本的平均混淆矩阵

Table 19 Average confusion matrix in testing samples given by hierarchical ER model

	融合故障诊断结果					总计	确诊率
	D ₁	D ₂	D ₃	D ₄	D ₄		
故障模式	D ₁	300	0	0	0	300	100%
	D ₂	0	284.6	15.4	0	300	94.9%
	D ₃	0	4	284.4	11.6	300	94.8%
	D ₄	0	0	10.1	289.9	300	96.6%

表 20 单层ER模型测试样本的平均混淆矩阵

Table 20 Average confusion matrix on testing samples given by single ER model

	融合故障诊断结果					总计	确诊率
	D ₁	D ₂	D ₃	D ₄	D ₄		
故障模式	D ₁	300	0	0	0	300	100%
	D ₂	3.5	278.5	14	4	300	92.8%
	D ₃	0	2	282.6	15.4	300	94.8%
	D ₄	5.2	0	14.5	280.3	300	93.4%

6 结论

本文针对多源不确定性故障特征信息融合决策问题, 给出基于分层ER规则的故障诊断方法. 首先

通过参考值投点获得参考证据矩阵, 生成点值型参考证据矩阵(REM)和在线故障特征样本的诊断证据; 给出分层式ER融合模型, 第1层融合中实现在线测试样本与近邻历史样本对应证据的融合; 在第2层融合中, 将多个特征源提供的第1层融合结果进行再次融合, 并根据两层融合所获证据进行故障决策; 在双层融合模型中, 根据证据之间的欧氏距离构造目标函数及相应的重要性权重优化方法; 最后通过对比故障确诊率, 可以得出本文的方法有效提升了故障诊断的精度.

本方法不仅继承了单层ER方法处理不确定性信息融合问题的优势, 还进一步解决了诊断证据的精细化获取问题和在线诊断信息量受限问题. 其优点在于: 1) 所提方法在诊断证据获取过程中, 给出故障特征参考值投点方法, 按比例求取特征样本点对相邻参考值的相似度, 生成点值型参考证据矩阵(REM)和在线故障特征样本的诊断证据, 实现了诊断信息的精细化提取; 2) 引入更多的相关历史样本参与融合推理过程, 增加推理模型接纳的有效信息量, 以增进辨识精度.

此外, 本文还有一些问题值得进一步探讨和研究: 1) 式(11)使用了基于距离的k-NN方法确定近邻样本, 本质是求取历史样本到中心样本的距离, 除此之外也可以进一步讨论使用其他距离度量方法

如马氏距离,当然还可以考虑使用多种距离算法,并对多个距离算法结果进行综合,后续的研究中可以就这一方面进行相关的验证;2)文中给出的实验案例所使用的样本数据集是完备的,然而实际上会存在无法确定样本的故障特征变量或者故障模式的情况,未来的研究中,可以就该方面对所提方法进行进一步的讨论和扩展。

参考文献:

- [1] WEN Chenglin, XU Xiaobin. *Multi-source Uncertain Information Fusion Theory and Application — Fault Diagnosis and Reliability Evaluation*. Beijing: Science Press, 2012.
(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. 北京: 科学出版社, 2012.)
- [2] XU Xiaobin, WEN Chenglin, SUN Xinya, et al. *Evidence Fusion and Decision Method in Equipment Fault Diagnosis*. Beijing: Science Press, 2017.
(徐晓滨, 文成林, 孙新亚, 等. 设备故障诊断中的证据融合与决策方法. 北京: 科学出版社, 2017.)
- [3] XU Xiaobin, WEN Chenglin, WANG Yingchang. Information fusion algorithm of fault diagnosis based on random set metrics of fuzzy fault features. *Journal of Electronics & Information Technology*, 2009, 31(7): 1635 – 1640.
(徐晓滨, 文成林, 王迎春. 基于模糊故障特征信息的随机集度量信息融合诊断方法. 电子与信息学报, 2009, 31(7): 1635 – 1640.)
- [4] ZHOU Y, CHANG L, QIAN B. A belief-rule-based model for information fusion with insufficient multi-sensor data and domain knowledge using evolutionary algorithms with operator recommendations. *Soft Computing*, 2019, 23(13): 5129 – 5142.
- [5] ISLAM M A, ANDERSON D, PINAR A, et al. Enabling explainable fusion in deep learning with fuzzy integral neural networks. *IEEE Transactions on Fuzzy Systems*, 2019, DOI: 10.1109/TFUZZ.2019.2917124.
- [6] LIN G, LIANG J, QIAN Y. An information fusion approach by combining multigranulation rough sets and evidence theory. *Information Science*, 2015, 314: 184 – 199.
- [7] MOOSAVIAN A, KHAZAEI M, NAJAFI G, et al. Spark plug fault recognition based on sensor fusion and classifier combination using Dempster-Shafer evidence theory. *Applied Acoustics*, 2015, 93: 120 – 129.
- [8] HUI K H, LIM M H, LEONG M S, et al. Dempster-Shafer evidence theory for multi-bearing faults diagnosis. *Engineering Applications of Artificial Intelligence*, 2017, 57: 160 – 170.
- [9] ZHAO F J, ZHOU Z J, HU C H, et al. A new evidential reasoning-based method for online safety assessment of complex systems. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 48(6): 954 – 966.
- [10] LIU Z G, PAN Q, DEZERT J, et al. Combination of classifiers with optimal weight based on evidential reasoning. *IEEE Transactions on Fuzzy Systems*, 2017, 26(3): 1217 – 1230.
- [11] YANG J B, XU D L. Evidential reasoning rule for evidence combination. *Artificial Intelligence*, 2013, 205(12): 1 – 29.
- [12] XU Xiaobin, ZHENG Jin, XU Dongling, et al. Information fusion method for fault diagnosis based on evidential reasoning rule. *Control Theory & Applications*, 2015, 32(9): 1170 – 1182.
(徐晓滨, 郑进, 徐冬玲, 等. 基于证据推理规则的信息融合故障诊断方法. 控制理论与应用, 2015, 32(9): 1170 – 1182.)
- [13] YANG J B, XU D L. A study on generalising Bayesian inference to evidential reasoning. *Belief Functions: Theory and Applications*. New York: Springer International Publishing, 2014: 180 – 189.
- [14] XU D L, YANG J B, WANG Y M. The evidential reasoning approach for multi-attribute decision analysis under interval uncertainty. *European Journal of Operational Research*, 2006, 174(3): 1914 – 1943.
- [15] COVER T, HART P. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 1967, 13(1): 21 – 27.
- [16] HASTIE T, TIBSHIRANI R. Discriminant adaptive nearest neighbor classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1996, 18(6): 607 – 616.
- [17] XU X B, ZHENG J, YANG J B, et al. Data classification using evidence reasoning rule. *Knowledge-Based Systems*, 2017, 116: 144 – 151.
- [18] GOLDBERG D E. *Genetic Algorithms in Search, Optimization and Machine Learning*. Reading, Massachusetts: Addison-Wesley, 1989, XIII.

作者简介:

徐晓滨 教授, 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;

叶梓发 硕士研究生, 研究方向为不确定信息处理、智能故障诊断, E-mail: yezifa1995@163.com;

徐晓健 讲师, 主要研究方向为状态监测、信息融合和智能决策, E-mail: xxj03@hdu.edu.cn;

侯平智 教授, 一带一路信息技术研究院院长, 主要研究方向为自动化控制系统集成、智能控制等, E-mail: houpingzhi@hdu.edu.cn;

王琪冰 教授级高工, 研究方向为特种机电设备状态监测与故障诊断, E-mail: 43410697@qq.com;

茹晓英 工程师, 研究方向为旋转机械系统的安全性评估、故障预测与健康管理等, E-mail: 77141480@qq.com.