

复杂干扰环境下相关证据推理的故障检测算法*

刘洋龙¹ 陈晓雷¹ 倪军² 梁楠³

(1. 重庆邮电大学自动化学院 重庆 400065; 2. 云南大学信息学院 昆明 650500;

3. 河南省科学院应用物理研究所有限公司 郑州 450003)

摘要: 现有基于证据理论的故障检测算法通常需假设证据具备独立性,但在实际工程中这一假设往往难以成立,尤其在数据源受到复杂环境干扰的情况下,可能导致理论分析与实际结果之间存在较大差异。针对上述问题,提出一种复杂干扰环境下相关证据推理的故障检测算法。首先,根据证据可靠度确定加权模型下的证据融合顺序,以降低复杂干扰造成融合结果的不确定性;然后,在证据融合阶段中考虑证据相关性,计算最大信息系数以评估证据间的关联程度;其次,根据证据依赖系数计算依赖折扣因子,并将其融入证据推理规则中;最后,考虑数据源的复杂干扰特性,借鉴统计学习的提升方法思想,设计双层证据决策机制计算最终的故障检测结果。通过航空电磁继电器的故障检测实验,验证了所提算法的可行性与有效性。与现有方法相比,算法的优势在于放宽了对证据独立性的要求,尤其适用于受噪声干扰较大的工程环境中。

关键词: 证据推理; 复杂干扰; 相关证据; 依赖系数; 提升方法

中图分类号: TN06; TP206

文献标识码: A

国家标准学科分类代码: 510.40

Fault detection algorithm based on evidential reasoning with dependent evidence under complex interference environment

Liu Yanglong¹ Chen Xiaolei¹ Ni Jun² Liang Nan³

(1. School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. School of Information Science and Engineering, Yunnan University, Kunming 650500, China;

3. Institute of Applied Physics, Henan Academy of Sciences, Zhengzhou 450003, China)

Abstract: Existing fault detection algorithms based on evidence theory typically assume that the evidence is independent. However, this assumption is often difficult to satisfy in practical engineering, especially when data sources are affected by complex interference environment, leading to significant discrepancies between theoretical analysis and actual results. In response to the above problems, a fault detection algorithm based on evidential reasoning with dependent evidence under complex interference environment is proposed. Initially, the evidence reliability is used to determine the evidence fusion sequence within a weighted model, reducing the uncertainty of fusion results caused by complex disturbances. Subsequently, considering the correlation of non-independent evidence in the evidence fusion stage, the maximum information coefficient is calculated to evaluate the degree of correlation between evidence. Furthermore, the dependence discounting factor is calculated based on the dependence coefficient of the evidence and incorporated into evidential reasoning rule. Lastly, considering the complex interference characteristics of data sources, a two-layer evidence decision-making mechanism inspired by boosting methods in statistical learning is designed to compute the final fault detection result. The feasibility and efficacy of the proposed algorithm are demonstrated through a fault detection experiment of aviation electromagnetic relays. Compared with existing methods, the advantage of the proposed algorithm is that it relaxes the requirement for independence of evidence, which is especially suitable for engineering environments that are subject to greater noise interference.

Keywords: evidential reasoning; complex interference; dependent evidence; dependence coefficient; boosting method

0 引言

随着生产力的快速发展,现代工业系统的复杂度和集成度也越来越高。这类系统在高负荷持续运行或受内外部复杂干扰叠加作用时,难免发生故障,关键部件的故障还可能引发连锁反应,导致重大的生命财产损失。实际上,工业现场获取的监测信息通常具有模糊性、非精确性及不确定性^[1],这也迫切需要先进的故障检测理论。证据理论在处理多源不确定信息方面具有很强的鲁棒性,适用于解决复杂系统的故障检测问题,已得到较为广泛的研究,现有方向主要围绕区间证据理论^[2]、新型证据组合机制^[3]、新型证据更新策略^[4]等展开,这在很大程度上推进了相关理论的工程应用。

基于证据理论的方法通常依赖一个关键前提条件,即需假设从多个特征数据中获取的证据之间具备独立性^[5],这与实际工程并非完全吻合,甚至可能是完全相悖的。例如,文献[6]采用电阻、电感与电容串联电路获取继电器特征参数,将触点电压及触点电流参数得到的证据融合结果作为故障检测判据。文献[7]研究一类桥梁结构故障检测问题,选取多个测量点的挠度及斜拉索应力参数作为证据来源。实际上,这些特征参数之间也存在强耦合或隐性关联的特点。需要说明的是,若实际工程并不满足证据独立性假设,则很难避免后续推理过程中存在过估计的问题,这将对最终的故障检测精度造成严重负面影响^[8]。现有检测方法的另一关键之处在于对数据源存在复杂干扰的处理问题,尤其在噪声干扰严重的工况下,经数据采集、信号传输及预处理环节后,特征数据中通常仍包含离群值或异常值。例如,在电力系统故障监测中,受外部环境、装置本体或设备状态变化影响,获取的数据流中总包含非高斯噪声及异常值^[9-10],在航天器^[11]、间歇过程^[12]、化工系统^[13-14]中也存在相似案例。若忽略复杂干扰下离群值或异常值的影响,证据推理后可能得到伪证据,经融合运算后易产生错误的检测结果。

综上所述,证据独立性假设与异常值处理问题很大程度上成为制约证据推理算法应用于复杂干扰下系统故障检测的关键瓶颈。文献[15]采用皮尔逊相关系数衡量证据之间的相关性,并分别计算每条证据源的总体相关系数。文献[16]考虑条件独立性问题,采用概率质量函数描述证据融合,并对 Dempster-Shafer 解析式进行扩展。文献[17]提出一种处理相关证据问题的精确建模方法,其核心思想是将证据相关性分解为内部依赖性和外部依赖性,分别采用决策实验室分析模型和分形理论进行处理,以降低证据冗余程度。文献[18]采用聚类法评估数据源之间的关联程度,设计相应的证据融合规则,

并给出基于 Pignistic 概率函数的应急证据备选方案。文献[19]提出量子质量函数距离的概念,以距离度量来表征证据集合间的差异程度,并设计了相应的融合规则。分析可知,上述方法对证据相关性进行了精确的数学建模,提出了非独立证据间的融合机制,契合证据理论所具备的数据驱动思想。不足之处在于,对于数据源存在复杂干扰的问题反而难以驾驭。将复杂干扰下的数据进行聚类分析或距离度量均将直接生成错误证据,且采用现有的证据推理框架难以处理实际工程中存在的数据耦合机理高度复杂或难以解析的问题。

针对上述问题,提出一种复杂干扰环境下相关证据推理的故障检测算法。首先,根据证据可靠度确定加权模型下的证据融合顺序,以降低复杂干扰造成融合结果的不确定性;然后,在证据融合阶段中考虑证据相关性问题,计算最大信息系数以评估证据间的关联程度;其次,根据证据依赖系数计算依赖折扣因子,将其融入证据推理规则中;最后,考虑数据源在复杂干扰下包含离群值或异常值的情况,借鉴统计学习的提升方法思想,设计双层证据决策机制计算最终的故障检测结果。本文算法的优势在于放宽了对证据独立性的要求,尤其适用于受噪声干扰较大的工程环境中。

1 证据融合

1.1 证据理论框架

在证据理论中,一个辨识框架通常被定义为 $\Theta = \{H_1, H_2, \dots, H_N\}$, 其中 H_1, H_2, \dots, H_N 表示一组相互排斥且可构成一个完备集的基本假设,即 $H_i \cap H_j = \emptyset, (i \neq j; i, j = 1, 2, \dots, N)$ 。单个特征数据在某一属性上的评价可以作为一条证据。假设一组特征数据在 L 个属性 $e_l (l = 1, 2, \dots, L)$ 上通过 N 个基本假设 $H_n (n = 1, 2, \dots, N)$ 进行评价^[20], 则 L 条证据可以表示为:

$$S(e_l) = \{(H_n, \beta_{n,l}), n = 1, 2, \dots, N\} \quad l = 1, 2, \dots, L \quad (1)$$

式中: $\beta_{n,l}$ 表示某条特征数据在属性 e_l 上被评价相对于假设 H_n 的信度,有 $0 \leq \beta_{n,l} \leq 1, \sum_{n=1}^N \beta_{n,l} = 1$ 。这里采用基于高斯分布的基本概率赋值方法生成 $\beta_{n,l}$ ^[21]。

为避免冲突证据融合后生成违反直观的融合结果,引入证据权重 $\omega_l (0 \leq \omega_l \leq 1, l = 1, 2, \dots, L)$ 与证据可靠度 $r_l (0 \leq r_l \leq 1, l = 1, 2, \dots, L)$ 对证据信度进行加权运算, $\omega_l = 1$ 和 $r_l = 1$ 分别表示证据最重要与完全可靠。证据推理规则中,证据权重与可靠度是两个重要参数。证据权重用于评估当前证据相较于其他证据的相对重要程度,证据可靠度则反映了当前证据对正确融合结果的支持度,对处理证据冲突问题具有重要意义^[22]。

采用离差系数评估多组特征数据的波动程度,设 k 时刻在属性 l 下的特征数据为 x_l^k ,在滑动窗口机制下的观测数据表示为 $\mathbf{X}_l = [x_l^{k-W_C+1}, \dots, x_l^{k-1}, x_l^k], l = 1, 2, \dots, L$,其中 W_C 表示计算证据权重时的滑动窗口长度, \mathbf{X}_l 的离差系数计算为^[23]:

$$\begin{cases} V_l(k) = \frac{\sqrt{\frac{1}{W_C - 1} \sum_{j=1}^{W_C} (x_l^{k-W_C+j} - \bar{x}_l(k))^2}}{\bar{x}_l(k)} \\ \bar{x}_l(k) = \frac{1}{W_C} \sum_{i=1}^{W_C} x_l^{k-W_C+i} \end{cases} \quad (2)$$

式中: $V_l(k)$ 为 k 时刻 \mathbf{X}_l 的离差系数; $\bar{x}_l(k)$ 为滑动窗口中的样本均值。可以看出,若离差系数取值较小,则特征数据接近于样本均值,其波动程度也较低。这意味着在相邻时间段内得到的故障证据差异性不显著,可反映系统运行状态变化的有效信息量也较少。将离差系数进行归一化处理,得到证据权重为:

$$\omega_l(k) = V_l / \sum_{i=1}^L V_i \quad (3)$$

证据推理规则中,证据可靠度可采用信息熵来评估,信息熵越高,意味着证据所含信息的不确定性越高,相应地,证据可靠度也越低。证据可靠度定义为:

$$\begin{cases} r_l = \frac{\log_2 N - E_l}{\max_i (\log_2 N - E_i)} \quad i = 1, 2, \dots, L \\ E_l = - \sum_{\theta \in \Theta} \beta_{\theta,l} \log_2(\beta_{\theta,l}) \end{cases} \quad (4)$$

式中: r_l 为第 l 条证据的可靠度。事实上,在基于权重和可靠度的加权推理框架下实现多条相关证据融合时,不同的融合顺序将得到不同的结果。因此,设计合理的证据融合顺序是处理相关证据融合问题的重要前提。

围绕证据可靠度设计证据融合顺序,以处理不满足证据独立性假设条件的故障检测问题。分析式(4)可知,若 r_l 较大,表明第 l 条证据的可靠度很高,其包含较多的可用信息且自身不确定性很低,证据的可信度也很高。根据证据可靠度进行排序,设计证据融合顺序为:

$$S = \{e_1, e_2, \dots, e_L \mid r_1 \geq r_2 \geq \dots \geq r_L\} \quad (5)$$

可知在数据源受复杂干扰时,所设计的证据融合运算将优先处理可靠度高的证据,其基本思想在于强调效率优先,在融合运算的初始阶段即可获得较高质量的证据融合结果,同时也最大程度降低了复杂干扰造成融合结果的不确定性,这也契合处理复杂多证据问题的专家经验。本文处理相关证据融合问题时,均参照上述规则。

1.2 证据依赖系数

证据理论的核心思想在于采用基本信度函数来度量信息的不确定性,所谓证据是在辨识框架内由特征数据计算得出^[24]。对于非独立的两条证据,其关联性可由对

应的特征数据间的动态关联性进行评估^[25]。采用最大信息系数度量两组特征数据之间的相关性,与皮尔逊相关系数相比,最大信息系数能够更好地表征非线性映射关系^[26],适用于处理复杂系统的多特征信息融合故障检测问题。

假设有 L 组不同数据源的时序特征数据 $[\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_L]$,定义 $\mathbf{X}_i, \mathbf{X}_j$ 之间的最大信息系数为:

$$\lambda_{i,j} = \max_{\mathbf{X}_i, \mathbf{X}_j \in B} \frac{I[\mathbf{X}_i, \mathbf{X}_j]}{\log_2(\min(|\mathbf{X}_i|, |\mathbf{X}_j|))} \quad (6)$$

式中: $\lambda_{i,j}$ 为 $\mathbf{X}_i, \mathbf{X}_j$ 间的最大信息系数,可视为相应生成的两条故障证据 $S(e_i)$ 与 $S(e_j)$ 间的相关系数; $I[\mathbf{X}_i, \mathbf{X}_j]$ 为 \mathbf{X}_i 和 \mathbf{X}_j 之间的互信息,满足:

$$I[\mathbf{X}_i, \mathbf{X}_j] = \sum_{\mathbf{X}_i, \mathbf{X}_j} p(\mathbf{X}_i, \mathbf{X}_j) \log_2 \frac{p(\mathbf{X}_i, \mathbf{X}_j)}{p(\mathbf{X}_i)p(\mathbf{X}_j)} \quad (7)$$

式中: $p(\mathbf{X}_i)$ 为边缘分布, $p(\mathbf{X}_i, \mathbf{X}_j)$ 为联合分布。由式(6)和(7)可知 $\lambda_{i,j} = \lambda_{j,i}$,且 $\lambda_{i,j} \leq 1 (i \neq j \leq L)$,有 $\lambda_{i,i} = 1$ 。若 $\lambda_{i,j}$ 越大,表明 $\mathbf{X}_i, \mathbf{X}_j$ 包含的关联信息也越多,相应地,非独立证据间的相互依赖程度也越高。

综上,可计算 L 条非独立证据之间的相关系数,根据式(5)确定的证据融合顺序,构造 L 维相关系数矩阵为:

$$\mathbf{M}_\lambda = \begin{bmatrix} \lambda_{1,1} & 0 & \dots & 0 \\ \lambda_{2,1} & \lambda_{2,2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ \lambda_{L,1} & \lambda_{L,2} & \dots & \lambda_{L,L} \end{bmatrix} \quad (8)$$

式中: \mathbf{M}_λ 为下三角矩阵,且其主对角线上的元素均为 1。

若前 i 条故障证据具备独立性,当第 i 条证据参与融合时,由证据融合规则可知,需与前 $i - 1$ 条证据组合的融合结果再进行融合。同理,若前 i 条故障证据并不满足独立性假设,当第 i 条证据参与融合时,除考虑与第 $i - 1$ 条证据间的相关性外,还需分析与所有已融合故障证据的相关性。定义第 i 条故障证据对其他已融合证据的依赖系数为:

$$\xi_i = \sum_{l=1}^i \lambda_{l,i}, l = 1, 2, \dots, L \quad (9)$$

式中: ξ_i 为证据 $S(e_i)$ 的依赖系数,即表示 $S(e_i)$ 与所有已融合证据之间相关系数之和,可由 \mathbf{M}_λ 中每一行元素相加得到。根据式(5)所示的证据融合顺序可知,第 1 条待融合证据的可靠度最高,其依赖系数也最小,此后每个待融合证据的依赖系数将依次增加。

为对相关证据进行精确的折扣操作,定义证据的依赖折扣因子为:

$$\psi_l = \frac{\bar{\psi}_l}{\max(\bar{\psi}_i)}, \bar{\psi}_l = \frac{1/\xi_l}{\sum_{i=1}^L 1/\xi_i} \quad i = 1, 2, \dots, L \quad (10)$$

式中: $\psi_l (0 \leq \psi_l \leq 1)$ 为第 l 条证据的依赖折扣因子。可以看出,依赖系数越高的故障证据,依赖折扣因子的数值

越小,其能够独立提供有用信息的能力就越弱。

1.3 相关证据推理

满足证据独立性前提的证据融合过程假定多个证据可同步获取,并采用适当的证据推理规则得到融合结果,也被称为静态融合过程。考虑实际工程问题,若从不同特征数据中获取的证据之间不符合独立性条件,相关证据的加权信度分布定义为:

$$m_{\theta,l} = \begin{cases} \tilde{\omega}_l \beta_{\theta,l}, & \theta \subseteq \Theta, \theta \neq \emptyset \\ 0, & \theta = \emptyset \\ 1 - \tilde{\omega}_l, & \theta = P(\Theta) \end{cases}$$

$$m_l = \{(\theta, m_{\theta,l}), \forall \theta \subseteq \Theta; (P(\Theta), m_{P(\Theta),l})\} \quad (11)$$

式中: m_l 为证据 $S(e_l)$ 的加权信度分布; $m_{\theta,l}$ 为 $S(e_l)$ 对

$$\begin{cases} m_{\theta,c(i)} = [m_1 \oplus \dots \oplus m_i](\theta) = \begin{cases} \frac{\hat{m}_{\theta,c(i)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,c(i)} + \hat{m}_{P(\Theta),c(i)}}, & \theta \neq \emptyset \\ 0, & \theta = \emptyset \end{cases} \\ \hat{m}_{\theta,c(i)} = \left[\frac{\omega_i}{\tilde{\omega}_i} (1 - \tilde{\omega}_i) m_{\theta,c(i-1)} + m_{P(\Theta),c(i-1)} m_{\theta,i} \right] + \sum_{A \cap B = \theta} m_{A,c(i-1)} m_{B,i}, \theta \subseteq \Theta \\ \hat{m}_{P(\Theta),c(i)} = \frac{\omega_i}{\tilde{\omega}_i} (1 - \tilde{\omega}_i) m_{P(\Theta),c(i-1)} \end{cases} \quad (13)$$

式中: $c(i)$ 表示前 i 条相关证据的融合结果; $m_{\theta,c(i)}$ 表示融合结果支持基本假设 θ 的加权信度。特别地, $m_{\theta,c(1)} = m_{\theta,1}, m_{P(\Theta),c(1)} = m_{P(\Theta),1}$ 。 L 条相关证据融合为一条证据后,其对基本假设 θ 的信度计算为:

$$\beta_{\theta} = \beta_{\theta,c(L)} = \begin{cases} \frac{\hat{m}_{\theta,c(L)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,c(L)}}, & \theta \neq \emptyset \\ 0, & \theta = \emptyset \end{cases} \quad (14)$$

对 k 时刻的特征数据 $\mathbf{X}^k = [x_1^k, x_2^k, \dots, x_L^k]$, 按照式(5)的融合顺序及式(11)的加权信度分布,利用式(13)~(14)的组合规则融合 k 时刻的多条故障证据,获取静态融合的证据,记为:

$$R_s(\mathbf{X}^k) = \{(H_n, \beta_n), n = 1, 2, \dots, N\} \quad (15)$$

式中: $R_s(\mathbf{X}^k)$ 为 \mathbf{X}^k 计算得到的融合结果,需要说明的是,该结果仅由 k 时刻的所有故障证据融合得出,并未考虑证据随时间的更新问题。

2 证据更新

2.1 迭代更新

根据人工经验可知,将待检对象的当前信息与历史状态信息进行综合对比分析,以获取对当前故障状态的判别依据,是实际工程中常用的故障决策方法,也使检测

假设 θ 的加权信度, $m_{P(\Theta),l}$ 为 $P(\Theta)$ 的加权信度, $P(\Theta)$ 表示尚未分配到任何基本假设的集合。可知,相关证据的加权信度分布满足 $\sum_{\theta \subseteq \Theta} m_{\theta,l} + m_{P(\Theta),l} = 1$ 。 $\tilde{\omega}_l$ 为综合考虑了证据权重、可靠度和依赖折扣因子的混合权重,其算式为:

$$\tilde{\omega}_l = \frac{\omega_l \cdot \psi_l}{1 + \omega_l - r_l} \quad (12)$$

式中: $\tilde{\omega}_l$ 为相关证据的混合权重。 $\psi_l = 1$ 表明该证据具备独立性。当 $\psi_l = 0$ 时,有 $\tilde{\omega}_l = 0$,表明该证据实质上是冗余信息,不影响最终的融合结果。

L 条相关证据进行融合时,前 i 条相关证据的融合如式(13)。

结论易具备可信性与可解释性。基于上述思想,将当前时刻证据与历史时刻证据进行动态融合,即利用当前证据对历史诊断证据进行迭代更新,以获取对待检对象故障状态更全面的检测结果。

对 k 时刻的特征数据进行静态融合计算,得到融合结果,记为 $R_s(\mathbf{X}^k) = \{(H_n, \beta_n), n = 1, 2, \dots, N\}$, 其与历史故障证据的迭代更新算式为:

$$R_h(\mathbf{X}^k) = R_h(\mathbf{X}^{k-1}) \oplus R_s(\mathbf{X}^k) \quad (16)$$

式中: $R_h(\mathbf{X}^{k-1})$ 表示 k 时刻的历史证据,则 $R_h(\mathbf{X}^k)$ 可视作 $k+1$ 时刻的历史证据,也表示 k 时刻经过证据推理后得到的故障证据,记为 $R_c(\mathbf{X}^k)$, 有 $R_c(\mathbf{X}^k) = R_h(\mathbf{X}^k)$ 。

2.2 双层证据决策

实际工程中,常用的观测数据通常来源于传感器量测,或是经数据采集、信号传输及预处理环节后得到的信号值,有时观测数据也来自估计或拟合算法。无论由何种途径获取,观测到的特征数据总是存在干扰,尤其在强干扰或噪声环境下,获取的特征数据通常包含离群值或异常值。这也是基于数据驱动的故障检测算法普遍面临的难题,即很难判别扰动的来源,究竟是系统故障还是外部干扰影响导致,有时仍需借助人工经验加以甄别。然而,现有证据推理框架通常不考虑复杂干扰环境问题,由精确数学模型及先验信息实现基本概率赋值。若将上述推理方法直接应用于实际工程,如果当前时刻的特征数

据为离群值或异常值,则采用该数据计算基本概率赋值时易生成错误证据,经式(13)相关证据融合运算后,其融合结果与实际情况可能产生显著偏差。此外,若数据源在时间/空间维度上受分布范围较广的复杂干扰影响,则在相邻时间段内可能生成较多的错误证据,经多次迭代更新后,将导致历史故障证据中也包含较多的错误信息,显著影响检测精度。

借鉴统计学习中的提升方法思想,设计双层证据决策机制。定义上层证据 $R_e(\mathbf{X}^k)$ 由静态融合与迭代更新后得到,下层证据 $R_d(\mathbf{X}^k)$ 则通过决策树分类器生成。将双层证据进行线性组合运算,获得最终的故障检测结果。 M 个时刻的时序特征数据记为 $[\mathbf{X}^1, \mathbf{X}^2, \dots, \mathbf{X}^M]$, 其中, k 时刻 ($k \in [1, M]$) 的特征数据经证据推理后,定义 $R_e(\mathbf{X}^k)$ 的故障检测结果为:

$$\begin{cases} G_e(\mathbf{X}^k) = \{G_e^n(\mathbf{X}^k), n = 1, 2, \dots, N\} \\ G_e^n(\mathbf{X}^k) = (N - 1) (\ln\beta_n - \frac{1}{N} \sum_{i=1}^N \ln\beta_i) \end{cases} \quad (17)$$

式中: N 为基本假设的数量; β_n 表示 $R_e(\mathbf{X}^k)$ 对基本假设 H_n 的信度; $G_e(\mathbf{X}^k)$ 表示经证据推理后得到的故障检测结果,满足 $\sum_{n=1}^N G_e^n(\mathbf{X}^k) = 0$ 。为解决现有证据推理框架难以处理数据源存在复杂干扰的问题,考虑在下层证据决策中,根据上层证据 $R_e(\mathbf{X}^k)$ 的分类表现,自适应增加错误分类的样本权重,同时也相应降低正确分类的样本权重。对每一项特征数据 \mathbf{X}^k 均赋予初始样本权重 $w_k = 1/M$, 样本权重的更新算式为:

$$\begin{aligned} \tilde{w}_k &= \frac{w_k}{Z} \exp\left(-\frac{N-1}{N} Y(\mathbf{X}^k) \ln R_e(\mathbf{X}^k)\right) \\ Z &= \sum_{k=1}^M w_k \exp\left(-\frac{N-1}{N} Y(\mathbf{X}^k) \ln R_e(\mathbf{X}^k)\right) \end{aligned} \quad (18)$$

式中: $Y(\mathbf{X}^k)$ 为 k 时刻设备实际运行状态的信度; \tilde{w}_k 为

k 时刻更新后的样本权重; Z 为规范化因子,其作用在于将 \tilde{w}_k 归一化。更新样本权重的基本思想是当 $Y(\mathbf{X}^k)$ 与 $R_e(\mathbf{X}^k)$ 不一致时,有 $\tilde{w}_k > w_k$, 即在 $R_e(\mathbf{X}^k)$ 错误时,更新后的样本权重 \tilde{w}_k 将增大,反之有 $\tilde{w}_k < w_k$ 。

基于更新后的样本权重,通过轮盘赌法获取训练数据集,并用于分类器的训练。权重大的样本意味着其仅由上层证据推理已很难得到正确的结果,需要组合决策树分类器得到的下层证据以实现准确分类。由此可知,下层证据更关注上层证据 $R_e(\mathbf{X}^k)$ 错误的样本数据。类似地,每个样本数据都对应存在一组滑动窗口数据 $\mathbf{X}^k = [x_1^k, x_2^k, \dots, x_L^k]$, \mathbf{X}^k 作为决策树分类器的输入数据,其中 $x_l^k = [x_l^{k-W_B+1}, \dots, x_l^{k-1}, x_l^k]$, $l = 1, 2, \dots, L$, W_B 为滑动窗口的长度。

在线故障检测过程中,根据下层证据 $R_d(\mathbf{X}^k)$, 按照式(17)得到对应的故障检测结果为 $G_d(\mathbf{X}^k)$, 将双层证据决策下分别获取的故障检测结果进行线性组合,有:

$$G(\mathbf{X}^k) = G_e(\mathbf{X}^k) + G_d(\mathbf{X}^k) \quad (19)$$

式中: $G(\mathbf{X}^k)$ 表示最终的故障检测结果。从机理上看,所提双层证据决策机制实质上是在现有证据推理框架的基础上增加了加权投票的决策环节,上层的相关证据推理更侧重于处理满足先验分布的特征数据,下层的证据决策策略更适用于处理数据源存在复杂干扰的情况,上下两层在实现故障检测的过程中具有互补关系。

3 故障检测算法流程

综上所述,所提复杂干扰环境下相关证据推理的故障检测算法,其流程如图1所示。算法的具体步骤归纳如下。

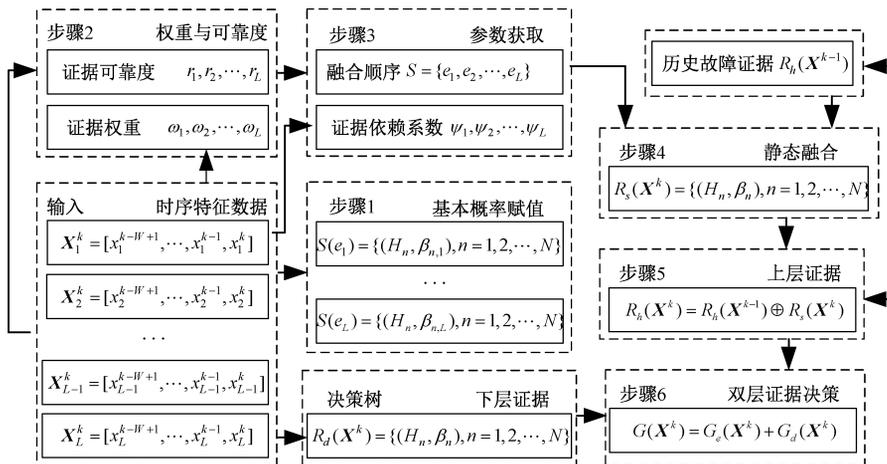


图1 算法流程

Fig. 1 Algorithm flowchart

步骤 1) 根据当前时刻输入的多组时序特征数据 \mathbf{X}_t^k , 按基本概率赋值计算对应的证据 $S(e_t)$;

步骤 2) 通过滑动窗口机制, 按式(2)~(4) 动态获取当前的证据权重 $\omega_1, \omega_2, \dots, \omega_L$ 和可靠度 r_1, r_2, \dots, r_L ;

步骤 3) 基于证据可靠度排序, 参照式(5) 确定多证据融合顺序, 据式(6)和(7) 计算最大信息系数, 并由式(8)~(10) 动态计算证据间的依赖系数 $\psi_1, \psi_2, \dots, \psi_L$;

步骤 4) 据式(12) 计算混合权重, 将其作为折扣因子并按式(11) 对证据信度进行加权运算, 随后据式(13) 进行融合计算, 按式(14)和(15) 获取当前时刻的静态融合结果 $R_s(\mathbf{X}^k)$;

步骤 5) 按式(16) 将当前时刻证据 $R_s(\mathbf{X}^k)$ 与历史证据 $R_h(\mathbf{X}^{k-1})$ 迭代更新, 得到 $R_c(\mathbf{X}^k)$;

步骤 6) 将滑动窗口中的特征数据输入到决策树分类器中, 得到 $R_d(\mathbf{X}^k)$, 并按式(17) 分别计算双层证据决策的故障检测结果, 根据式(19) 得到最终的故障检测结果 $G(\mathbf{X}^k)$ 。

4 实验验证

4.1 实验平台设计

为验证本文算法的有效性, 设计以电磁继电器为待检对象的故障检测实验平台。电磁继电器作为电气控制器件广泛应用于工业系统, 其可靠性对整体系统的安全性具有重要意义。继电器故障可分为突发性故障和隐性故障两类, 突发性故障通常指开关功能失效, 隐性故障的判别则极为困难。随着动作次数的增加, 继电器内部零部件将出现不同程度的性能老化, 可能发生吸合不稳定、释放粘滞、导通阻抗超限或触头弹跳显著等现象, 统称为隐性故障。常见参数如吸合电压、吸合时间、超程时间、弹跳时间及接触电阻等都可作为表征继电器性能与退化程度的特征数据, 例如, 吸合电压、吸合时间均反映了继电器的吸合灵敏性, 二者显然是高度关联的, 但从机理上看, 其侧重点也并非完全一致。吸合电压更倾向于评估电磁性能, 而吸合时间还包含了反映触簧运动性能的信息, 这表明仅依赖单一特征参数检测继电器隐性故障是很不全面的, 另一方面, 也说明多特征数据的独立性假设条件是很难契合工程实际的。更为关键的是, 继电器每次吸合时, 触点的接触位置与接触压力存在细微差异, 这也使得所有特征参数均具备一定程度的随机性和不确定性, 且随继电器性能的持续退化而益发显著。在继电器关断过程, 控制回路中的电感容量易引发触点火花放电或形成电弧, 对于测量单元而言, 意味着环境中存在非均匀的瞬变强磁场干扰, 也是导致测量数据普遍包含复杂干扰的重要因素^[27]。综上, 电磁继电器故障检测问题具备很高的复杂性, 可充分验证本文算法的有效性。

自主研发的电磁继电器故障检测实验平台框架如图 2 所示, 该实验平台由下位机、上位机、直流电源、待测继电器及负载构成。下位机负责控制继电器周期性开通/关断, 并同步采集继电器通断过程中的特征数据, 通过 LAN 将数据传输至上位机进行显示。上位机的功能包括发送控制指令、存储数据, 运行故障检测算法等。

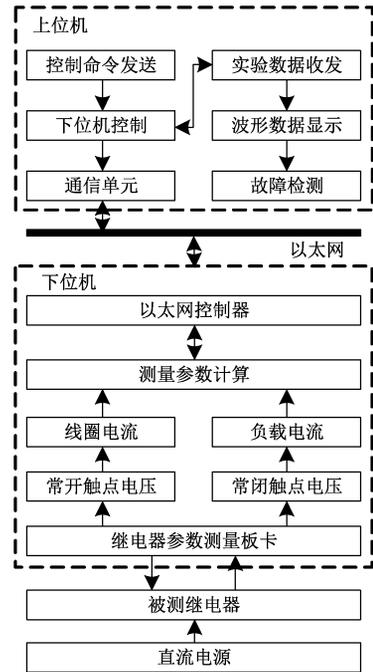


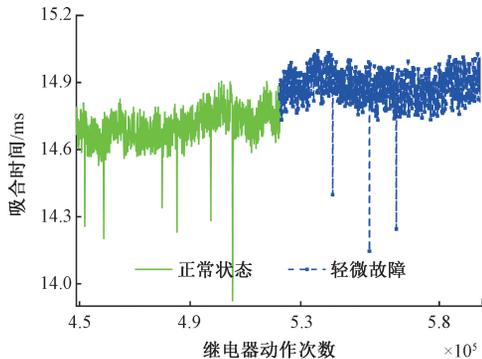
图 2 实验平台框架

Fig. 2 Experimental platform framework diagram

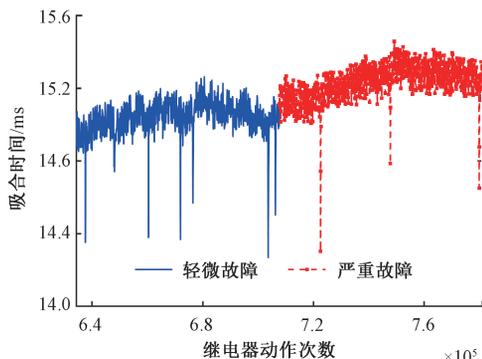
4.2 实验数据获取

在相同的负载条件下, 同步不间断测量多组相同型号电磁继电器的特征参数, 直至产生显著的故障信息。通过上位机存储时序特征数据, 随机将一组继电器产生的数据作为训练集, 其余继电器产生数据作为测试集。根据电磁继电器的运行状态差异, 定义 3 类工况, 分别为正常状态、轻微故障状态和严重故障状态。实质上, 继电器故障机理与性能退化相关, 如触头磨损或烧蚀、衔铁行程减小、触簧分断力下降等, 所谓轻微故障状态和严重故障状态实质上是评估继电器隐性故障程度的定性表述。相应地, 实验采用的辨识框架表示为 $\Theta = \{H_1, H_2, H_3\}$ 。 H_1, H_2, H_3 分别表示继电器处于正常状态、轻微故障状态及严重故障状态, 3 个属性对应的特征参数为吸合时间、吸合电压与接触电阻, 可较为全面地评估继电器的吸合能力和接触性能。以吸合时间为例来说明实验数据的特征, 随动作次数的变化曲线如图 3 所示。图 3 中, 横坐标表示继电器导通/关断的动作次数, 纵坐标表示吸合时间测量值。为凸显继电器不同工作状态间的变化情况, 仅给出状态变化前后的测量结果曲线。图 3(a) 为继电器

由正常工作状态到轻微故障状态的参数变化,图3(b)为继电器由轻微故障状态到严重故障状态的参数变化。从图3可以看出,数据存在一定范围的扰动,这是由于机理上即存在不确定性,另一方面也包含测量误差信息。随着继电器通断动作次数的增加,吸合时间整体呈逐渐增大的趋势,这也准确反映了吸合能力的退化。此外,特征数据中也包含了较为显著的离群值或异常值,这可能是由强电磁干扰及测量误差等多种因素共同导致。



(a) 正常状态过渡到轻微故障状态
(a) Normal state transitions to minor fault state



(b) 轻微故障状态过渡到严重故障状态
(b) Minor fault state transitions to severe fault state

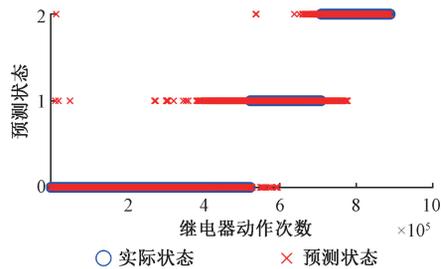
图3 吸合时间参数的变化曲线

Fig. 3 Variation curve of pull-in time parameter

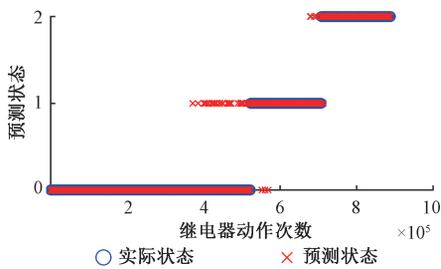
4.3 实验结果分析

由继电器的工作原理可知,吸合时间、吸合电压与接触电阻3个特征参数之间均具备相关性,其关联程度很难通过机理模型精准量化。为验证所设计的依赖折扣因子在处理非独立特征数据问题中的意义,在相同实验条件下,对比不同证据推理规则在故障检测能力方面的差异。实验对比结果如图4所示。

图4(a)为采用常规证据推理规则得到的实验结果,图4(b)则是在上述方法基础上,增加依赖折扣因子得到的实验结果。图4中,横坐标为继电器动作次数,纵坐标表示继电器预测状态,其值为0、1、2分别表示继电器处于正常状态、轻微故障状态及严重故障状态。圆形散点表示继电器的实际工况,叉形散点表示由证据推理得到



(a) 常规证据推理规则
(a) Conventional evidential reasoning rule



(b) 带依赖折扣因子的证据推理规则
(b) Evidential reasoning rule with dependence discounting factor

图4 依赖折扣因子对检测精度的影响

Fig. 4 The impact of dependence discounting factor on detection accuracy

的继电器工况,两类散点的重合度越高,则表明故障检测的精度也越高。由图4(a)可以看出,采用常规证据推理规则处理多特征数据融合故障检测问题时,若实际工况不满足证据独立性前提,得到的检测精度显著偏低,漏报率及误报率均较高。特别地,在实验起始阶段,继电器显然处于正常状态,由于未考虑数据关联性,误判继电器处于严重及轻微故障状态,得到错误的判断结果,这显然是违背事实的。从机理上看,在证据之间存在相关性时,意味着在某条证据中包含了另一条证据的冗余信息,直接应用常规证据推理规则会导致信息的重复运算,尤其在某条证据有误时,信息重复运算可能放大这种错误,导致最终检测结果很难达到较高的准确性。与图4(a)相比,图4(b)的检测精度得到明显提升,但在状态过渡环节仍存在较多的误判现象,尤其是从正常状态过渡到轻微故障状态时较为显著。

分析所提依赖折扣因子对证据推理规则的性能影响,上述两种方法的信度变化曲线如图5所示。图5中,横坐标为继电器动作次数,纵坐标表示最终得到的继电器故障证据信度,两条加粗竖线表示继电器状态过渡的交界线。从图5(a)可以看出,采用常规证据推理规则时信度计算结果不够理想,误判的情况较明显,也表明算法的检测性能较差。与之相比,图5(b)所呈现的算法性能得到了明显改善,这表明基于依赖折扣因子的设计有效降低了数据关联性对检测结果的负面影响。在状态过渡附近,仍存在明显的误判。

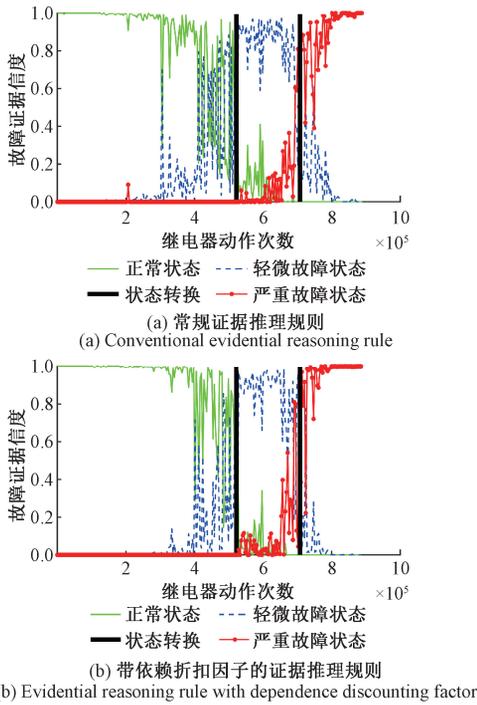


图 5 依赖折扣因子对检测性能的影响
Fig. 5 The impact of dependence discounting factor on detection performance

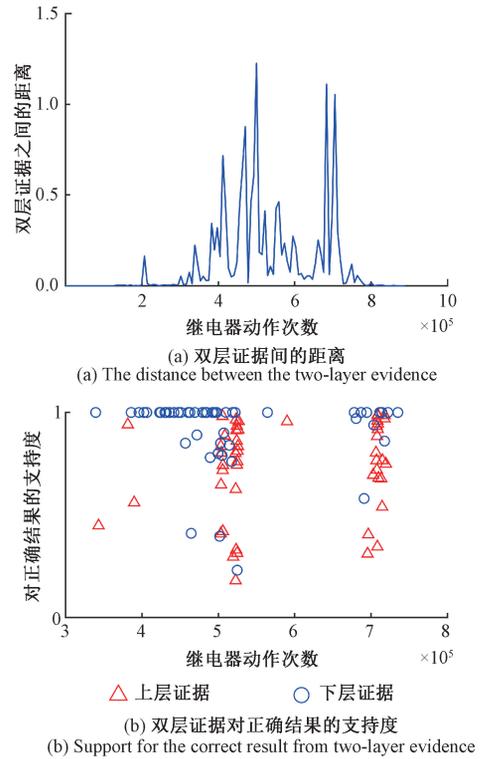


图 6 双层证据决策机制
Fig. 6 Two-layer evidence decision-making mechanism

为验证所提双层证据决策机制的有效性,先给出实验结果如图 6 所示。双层证据决策机制的核心在于,通过两类不同的基本概率赋值方法生成故障证据,最后将上下两层检测结果进行线性组合。为观测同一时刻双层证据间的结果差异,采用欧氏距离计算双层证据间的距离,其结果如图 6(a)所示。

数据源存在复杂干扰时,上下两层故障证据存在一定的差异,若这种差异较大时,则会产生证据冲突,即对继电器的状态判别结果不一致。当上下两层证据存在冲突,且通过双层证据决策机制得到正确的故障检测结果时,上层或下层证据对正确结果的支持度如图 6(b)所示。可以看出,上层证据推理在继电器状态过渡阶段发挥着主要作用,更侧重于处理满足先验分布的特征数据,下层证据决策策略更适用于处理数据源存在复杂干扰的情况,上下两层证据在实现故障检测的过程中具备互补关系,可显著降低复杂干扰对故障检测精度的影响。

采用所提算法得到实验结果,如图 7 所示。由图 7(a)可以看出,本文算法实现了继电器实际状态与预测状态的高度吻合,显著优于图 4 所示的实验效果,这也表明所提算法的有效性。由图 7(b)可以看出,本文算法表现出优异的检测性能,在继电器工作状态的过渡区域,信度值基本都保持在理想水平,且响应迅速,体现了算法具备很高的运行效率。与图 5 相比较可以看出,本文算

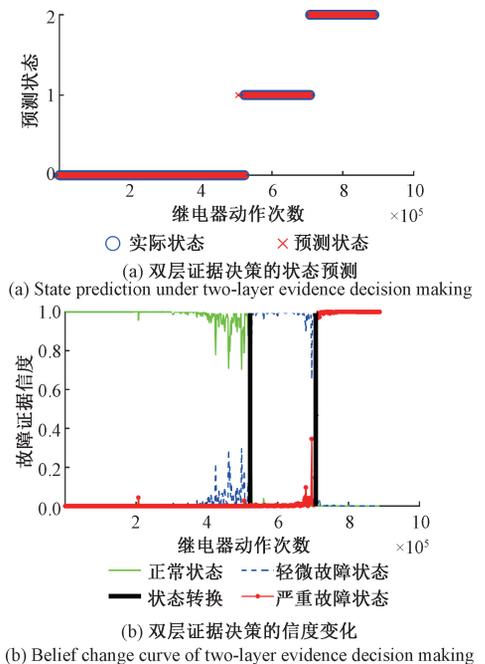


图 7 所提算法的故障检测结果
Fig. 7 Fault detection results of the proposed algorithm

法显著降低了复杂干扰对故障检测精度的影响,这是由于增加了双层证据决策机制,进一步提升了算法的决策

能力。

5 结 论

聚焦证据相关性问题的同时,同时考虑数据源存在复杂干扰的情况,提出一种复杂干扰环境下相关证据推理的故障检测算法。本文算法采用依赖折扣因子评估证据间的关联程度,改进了相关证据融合方法,并设计双层证据推理机制以降低数据源异常对故障检测结果的影响。本文算法的优势在于放宽了对证据独立性的要求,尤其适用于强噪声干扰等复杂环境。电磁继电器故障检测实验结果表明,该算法充分融合了证据推理规则与提升方法的优势,较好地解决了数据源存在复杂干扰的难题,且算法的检测精度高,可解释性强,对证据理论应用于复杂干扰下的系统故障检测具有重要意义。值得注意的是,算法的性能很大程度上依赖先验知识与信度分配,这也是未来证据推理算法的研究内容。

参考文献

- [1] NING P Y, ZHOU ZH J, CAO Y, et al. A concurrent fault diagnosis model via the evidential reasoning rule[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71(1): 1-16.
- [2] XU X B, GUO H H, ZHANG Z H, et al. A cloud model-based interval-valued evidence fusion method and its application in fault diagnosis [J]. Information Sciences, 2024, 658(7): 1-20.
- [3] LIN G, LIANG J, QIAN Y. An information fusion approach by combining multigranulation rough sets and evidence theory[J]. Information Sciences, 2015, 314(25): 184-199.
- [4] FENG ZH CH, YANG R H, ZHOU ZH J, et al. Online fault diagnosis and tolerance based on multiexpert joint belief rule base for sensor failures of vehicles[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72(1): 1-13.
- [5] SHANG Q Y, LI H W, DENG Y, et al. Compound credibility for conflicting evidence combination: An autoencoder-K-means approach[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 52(9): 5602-5610.
- [6] WANG J, ZHOU ZH J, HU CH H, et al. A fusion approach based on evidential reasoning rule considering the reliability of digital quantities [J]. Information Sciences, 2022, 612(31): 107-131.
- [7] XU X, FORDE M C, REN Y, et al. Multi-index probabilistic anomaly detection for large span bridges using bayesian estimation and evidential reasoning[J]. Structural Health Monitoring, 2023, 22(2): 948-965.
- [8] ZHANG P, ZHOU ZH J, FENG ZH CH, et al. Inference and analysis on the evidential reasoning rule with time-lagged dependencies [J]. Engineering Applications of Artificial Intelligence, 2023, 126(15): 1-22.
- [9] 马文涛,寇晓,郭耀松,等. 基于扩展 KRSL 无迹卡尔曼滤波的约束动态状态估计[J]. 电力系统自动化, 2023, 47(6): 185-196.
- MA W T, KOU X, GUO Y S, et al. Constrained dynamic state estimation based on extended kernel risk sensitive loss unscented Kalman filter[J]. Automation of Electric Power Systems, 2023, 47(6): 185-196.
- [10] 李岩,滕云,冷欧阳,等. 数据驱动的输电线路在线监测装置可靠性评估[J]. 中国电机工程学报, 2018, 38(15): 4410-4419.
- LI Y, TENG Y, LENG OU Y, et al. Reliability evaluation of on-line monitoring device over transmission line based on data driven concept[J]. Proceedings of the CSEE, 2018, 38(15): 4410-4419.
- [11] 彭会湘,刘光辉,陈韬亦,等. 一种基于离散时间段的测运控数据异常检测方法[J]. 无线电工程, 2021, 51(6): 458-469.
- PENG H X, LIU G H, CHEN T Y, et al. An anomaly detection method for satellite TT&C and operation data based on discrete time period [J]. Radio Engineering, 2021, 51(6): 458-469.
- [12] 刘伟旻,王建林,邱科鹏,等. 基于 DHSC 的多模态间歇过程测量数据异常检测方法[J]. 化工学报, 2017, 68(11): 4201-4207.
- LIU W M, WANG J L, QIU K P, et al. Method for detecting abnormal data in multimode batch processes based on dynamic hypersphere structure change [J]. CIESC Journal, 2017, 68(11): 4201-4207.
- [13] 刘伟旻,王建林,邱科鹏,等. 基于多证据融合决策的间歇过程测量数据异常检测方法[J]. 化工学报, 2017, 68(8): 3183-3189.
- LIU W M, WANG J L, QIU K P, et al. Multi-evidence fusion decision-making method for detecting abnormal data of batch processes [J]. CIESC Journal, 2017, 68(8): 3183-3189.
- [14] 吴晓阳,张森,陈先中,等. 高炉煤气流分布过程的多算法融合预测模型[J]. 控制理论与应用, 2020, 37(6): 1241-1252.
- WU X Y, ZHANG S, CHEN X ZH, et al. Multi-algorithm fusion prediction model for the blast furnace gas

- flow distribution process [J]. *Control Theory and Technology*, 2020, 37(6): 1241-1252.
- [15] 唐帅文, 曹友, 张朋, 等. 基于相关证据推理规则的激光惯组健康评估[J]. *航空学报*, 2024, 45(12): 211-228.
TANG SH W, CAO Y, ZHANG P, et al. Health assessment of LIMU based on evidential reasoning rule with dependent evidence [J]. *Acta Aeronautica et Astronautica Sinica*, 2024, 45(12): 211-228.
- [16] NAKAMA T, RUSPINI E. Combining dependent evidential bodies that share common knowledge [J]. *International Journal of Approximate Reasoning*, 2014, 55(9): 2109-2125.
- [17] MAO SH ZH, HAN Y ZH, DENG Y, et al. A hybrid DEMATEL-FRACTAL method of handling dependent evidences [J]. *Engineering Applications of Artificial Intelligence*, 2020, 91(5): 1-13.
- [18] 陈雪龙, 王亚丽. 考虑信息源相关性的多属性应急决策方法[J]. *系统工程理论与实践*, 2018, 38(8): 2045-2056.
CHEN X L, WANG Y L. The method for multi-attribute emergency decision-making considering the interdependence between information sources [J]. *Systems Engineering Theory & Practice*, 2018, 38(8): 2045-2056.
- [19] PAN L P, GAO X ZH, DENG Y. A distance of quantum mass function and its application in multi-source information fusion method based on discount coefficient [J]. *Engineering Applications of Artificial Intelligence*, 2022, 116(10): 1-11.
- [20] TANG SH W, ZHOU ZH J, HU CH H, et al. Perturbation analysis of evidential reasoning rule [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(8): 4895-4910.
- [21] WANG J, ZHOU ZH J, HU CH H, et al. Performance evaluation of aerospace relay based on evidential reasoning rule with distributed referential points [J]. *Measurement*, 2021, 182(16): 1-18.
- [22] MA ZH ZH, ZHU J J, CHEN Y. A probabilistic linguistic group decision-making method from a reliability perspective based on evidential reasoning [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, 50(7): 2421-2435.
- [23] ZHAO F J, ZHOU ZH J, HU CH H, et al. A new evidential reasoning-based method for online safety assessment of complex systems [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, 48(6): 954-966.
- [24] 蔡军, 肖乔元, 吴凡. 基于超程时间测量的电磁继电器故障检测[J]. *电子测量与仪器学报*, 2023, 37(6): 93-100.
CAI J, XIAO Q Y, WU F. Fault detection of electromagnetic relay based on super-path time measurement [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(6): 93-100.
- [25] 苏晓燕, 韩文花, 许培达, 等. 相关证据融合综述[J]. *系统工程与电子技术*, 2016, 38(6): 1345-1351.
SU X Y, HAN W H, XU P D, et al. Review of combining dependent evidence [J]. *Systems Engineering and Electronics*, 2016, 38(6): 1345-1351.
- [26] LIANG T, ZHANG Q, LIU X, et al. Time-frequency maximal information coefficient method and its application to functional corticomuscular coupling [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(11): 2515-2524.
- [27] 李文华, 桑海爽, 项石虎, 等. 基于可恢复冲击效应的继电器可靠性评估方法[J]. *仪器仪表学报*, 2022, 43(11): 200-209.
LI W H, SANG H SH, XIANG SH H, et al. Reliability evaluation method of relay based on recoverable shock effect [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(11): 200-209.

作者简介



刘洋龙(通信作者), 2022 年于湖南科技大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为证据理论、机器学习与故障检测。

E-mail: yanglongliu@163.com

Liu Yanglong (Corresponding author)

received his B. Sc. degree from Hunan University of Science and Technology in 2022. Now he is a M. Sc. candidate in Chongqing University of Posts and Telecommunications. His main research interests include evidence theory, machine learning and fault detection.



陈晓雷, 2016 年于西北工业大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为检测技术与自动化装置。

E-mail: chenxiaolei@cqupt.edu.cn

Chen Xiaolei received his Ph. D. degree from Northwestern Polytechnical University.

Now he is a lecturer in Chongqing University of Posts and Telecommunications. His main research interests include detection technology and automation device.



倪军, 2016 年于北京化工大学获得学士学位, 2022 年于北京化工大学获得博士学位, 现为云南大学讲师, 主要研究方向遥感图像解译与人工智能。

E-mail: jun.ni@ynu.edu.cn

Ni Jun received his B. Sc. degree from Beijing University of Chemical Technology in 2016, and Ph. D. degree from Beijing University of Chemical Technology in 2022, respectively. Now he is a lecturer in Yunnan University. His main research interests include remote sensing image interpretation and artificial intelligence.



梁楠, 2003 年于同济大学获得学士学位, 2008 年于西北工业大学获得硕士学位, 2013 年于西北工业大学获得博士学位, 现为河南省科学院副研究员, 主要研究方向为图像处理与人工智能。

E-mail: liangn@hnas.ac.cn

Liang Nan received his B. Sc. degree from Tongji University in 2003, M. Sc. degree from Northwestern Polytechnical University in 2008 and Ph. D. degree from Northwestern Polytechnical University in 2013, respectively. Now he is an associate researcher in Henan Academy of Sciences. His main research interests include image processing and artificial intelligence.