

基于 D-S 证据理论的城市轨道交通车辆 车门亚健康融合诊断方法

史华东^{1,2} 陆宁云^{1,2} 许志兴² 陈健飞²

(1. 南京航空航天大学自动化学院, 211106, 南京;

2. 南京康尼机电股份有限公司, 211106, 南京//第一作者, 硕士研究生)

摘 要 为了实现城市轨道交通车辆车门亚健康状态的精确诊断,提出基于 D-S 证据理论的车门亚健康融合诊断方法。根据车门驱动电机数据与门控器的 I/O 信号数据,分别运用 K-means 聚类与贝叶斯分类的方法构建车门亚健康初步诊断模型;引入 D-S 证据融合理论进行决策层的信息融合,得到更加准确的亚健康诊断模型。应用结果表明,该方法可显著提高车门亚健康诊断模型的准确性和可靠性。

关键词 城市轨道交通; 车辆; 车门; 亚健康融合诊断方法; D-S 证据理论

中图分类号 U270.38+.6; U279.3+23

DOI:10.16037/j.1007-869x.2022.06.012

Urban Rail Transit Vehicle Door Sub-health Fusion Diagnosis Method Based on D-S Evidence Theory

SHI Huadong, LU Ningyun, XU Zhixing, CHEN Jianfei

Abstract In order to realize accurate diagnosis of the sub-health status of urban rail transit vehicle door, a method for vehicle door sub-health fusion diagnosis method based on D-S evidence theory is proposed. Based on the door drive motor data and the I/O signal data of the door controller, K-means clustering and Bayesian classification are respectively used to construct a preliminary diagnosis model of door sub-health; D-S evidence fusion theory is introduced for information fusion at decision-making level, to obtain a more accurate sub-health diagnostic model. Application results show that the method can significantly improve the accuracy and reliability of the vehicle door sub-health diagnosis model.

Key words urban rail transit; vehicle; vehicle door; sub-health fusion diagnosis method; D-S evidence theory

First-author's address College of Automation Engineering, Nanjing University of Aeronautics & Astronautics, 211106, Nanjing, China

通过对城市轨道交通车辆车门系统健康状态的监测发现,随着列车的持续运行,车门各部件由于元件老化及磨损会导致车门处于亚健康状态,直接影响着车门的正常使用性能^[1]。及时发现并准确诊断城市轨道交通车辆车门的亚健康状态对其安全运行与高效率的维护具有重要意义。

文献[2]提出一种基于信息增益率的随机森林方法,构建了车门故障诊断模型。文献[3]通过特征优选算法筛选出最优特征子集,利用随机森林算法实现了地铁车门微小故障诊断。文献[4]基于 JS 散度,计算车门实时状态与参考健康状态的数据统计分布相似性,以检测车门系统的异常状态。上述故障诊断方法均基于单一数据源进行研究,采集的车门信息不够充分,导致最终诊断结果的准确性和可靠性较低。为此,本文提出基于 D-S 证据理论的车门亚健康融合诊断方法。对车门驱动电机数据与电子控制器 I/O(输入/输出)信号,分别利用 K-means 聚类与贝叶斯推理得到亚健康初步诊断结果,再基于 D-S 证据理论在决策层进行信息融合,构建更加精确的车门亚健康诊断模型。应用结果表明,该方法可显著提高车门亚健康诊断模型的可靠性和准确性。

1 城市轨道交通车辆车门控制系统

1.1 车门结构及其亚健康类型

本文以南京康尼公司的电动双开塞拉门作为研究对象。其车门主要由承载导向机构、门控系统、传动锁闭机构、密封装置等部分组成。除了基本的机械结构,车门核心的门控系统主要由电子门控制器与行程开关等电气部件构成。门控制器作为控制中心,负责发出开关门指令信号,同时能够接收行程开关反馈的开关量信号。

在列车长期的运营中,环境多变、乘客挤压及车门维保不及时等原因使车门部件易出现松动、失效、间隙等情况,进而导致车门处于亚健康状态运行。这些微小的亚健康状态往往具有隐蔽性、偶发性与模糊性,难以被及时发现。根据地铁车门健康状态监测的实际需求,本文研究了表1中所列的7种亚健康类型。

表1 车门亚健康状态

Tab.1 Vehicle door sub-health status	
亚健康状态	潜在影响
对中尺寸异常	开门阻力增大,甚至无法关闭
V型尺寸异常	影响门的密闭性,严重时导致关门异常
下挡销横向干涉	开门阻力增大,甚至无法关闭
上滑道异常内调	开关门过程阻力异常
上滑道异常外调	开关门过程阻力异常
缓冲头磨损	影响车门开度,降低对车门的保护性
压轮过松	影响门的密闭性

1.2 车门可测量数据

基于数据驱动的故障诊断方法对离线数据的信息充足性和完整性有一定的要求^[5]。通过轨道交通车辆车门远程监控与故障诊断系统^[6]在车门上的应用,实时获取车门运行数据。这些数据包含了详细的车门状态信息,可充分满足基于数据驱动的故障诊断要求。

地铁车辆车门通过传感器采集的数据主要分为驱动电机数据和智能门控器 I/O 信号两类。这两种不同类型的数据所反映的车门信息具有较大的差异性,驱动电机数据主要反映车门连续运动过程中的特点,门控器 I/O 信号包含了车门受控系统信息,可以反映车门状态的时变特性。

本文采集的电机数据包含转速、转角、电流 3 个变量。图1为正常开关门过程中车门电机数据曲线图。由图1可知,正常1次开关门的时间约为3.5 s。传感器采样周期为10 ms,每条数据大约采样350个点。

门控器 I/O 信号共包含了车门系统 20 种不同的控制信号与开关反馈信号。这些信号量为典型的离散数据信号,其状态只用数字 0 和 1 表示。表2为具体的 I/O 信号量类型。在车门开关门过程中,与车门状态变化相关的信号量较少,因此 I/O 信号较之电机数据包含的车门信息相对缺乏。

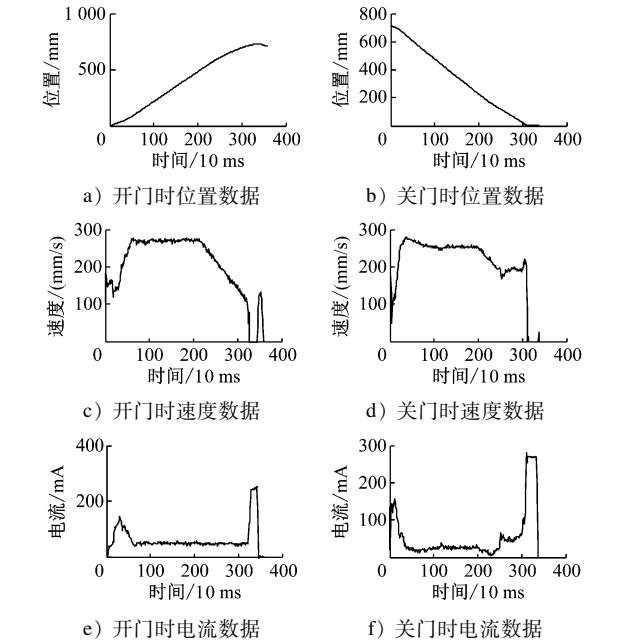


图1 正常开关门过程车门电机数据曲线
Fig.1 Vehicle door motor data curve of normal opening-closing process

表2 门控器 I/O 信号量
Tab.2 Door controller I/O signals

I/O 信号量	含义	I/O 信号量	含义
I0	紧急解锁开关	I11	关门列车线
LockPoint	锁到位开关	I12	重开门列车线
I2	隔离开关门	I13	门允许信号
I3	安全互锁回路	I14	开关门控制切换
ClosePoint	关到位开关	I15	零速列车线
I6	门地址编码位 1	I28	维护按钮
I7	门地址编码位 2	I29	VMMOK
I8	门地址编码位 3	O0	内侧车门指示灯
I9	门地址编码位 4	O1	车门切除指示灯
I10	开门列车线	O2	蜂鸣器

注:VMMOK 为电机母线电压。

2 基于 D-S 证据理论的车门亚健康融合诊断方法

2.1 D-S 证据理论

D-S 证据理论作为一种常用的信息融合方法,其提供的理论方法可以进行证据间的合成,在不确定性的表示和组合方面具有较多优势。在 D-S 证据理论中,假设研究对象的所有相互独立、互斥的事件结果用集合 Θ 表示,集合 Θ 称为识别框架。对识别框架中的某个事件 $\forall A \subseteq 2^\Theta$,映射 $m:2^\Theta \rightarrow [0,$

1]需满足:

$$\begin{cases} m(\Theta) = 0 \\ \sum_{A \subseteq \Theta} m(A) = 1 \end{cases} \quad (1)$$

式中:

\emptyset ——空集;

m ——基本概率分配(BPA)函数;

A ——研究对象发生的可能事件。

$m(A)$ 为事件 A 发生的基本概率分配值,表示对结果 A 的信任程度。此外,定义信任函数 $B_{el}(A)$ 与似然函数 $P_1(A)$ 来表示多子集事件 A 发生的所有可能概率。

$$B_{el}(A) = \sum_{B \subseteq A} m(B) \quad (2)$$

$$P_1(A) = \sum_{B \cap A \neq \emptyset} m(B) = 1 - B_{el}(\bar{A}) \quad (3)$$

式中:

B ——事件 A 的子集事件。

$B_{el}(A)$ 表示对事件 A 发生的支持程度, $P_1(A)$ 表示对事件 A 的不怀疑程度,两者共同构成事件 A 的信度区间 $[B_{el}(A), P_1(A)]$ 。

当同一个识别框架下出现多个证据体能够对被测对象的结果进行独立判断时,可以通过 D-S 证据合成规则进行组合,得到新的基本概率分配结果 m_{12} 。假设 m_1 和 m_2 为两个独立事件 B 、 C 的基本概率分配,进行组合后的结果为:

$$\begin{cases} m_{12} = \frac{1}{K} \sum_{B \cap C = A} m_1(B) m_2(C) \\ K = \sum_{B \cap C \neq \emptyset} m_1(B) m_2(C) \end{cases} \quad (4)$$

式中:

K ——冲突系数,表示证据之间的冲突程度。

2.2 车门数据预处理

车门部件发生损坏、尺寸变化、处于亚健康状态等情况时,都会导致电机的输出曲线发生变化。为了准确区分每种亚健康状态,根据车门的运动特点,将车门整体运动过程分为升速段、高速段、减速段、缓行段与到位后段,具体分段如图 2 所示。

根据图 2 车门运动过程的阶段划分,对电机的 3 个测量数据进行时域特征提取。本文提取的特征包括最大值、最小值、均值、峰值、方差、偏度、峭度,以及每段车门数据的行程与时间。对每个电机参数提取 93 个特征值,在每条数据中共提取 279 个特征组成特征向量 $\mathbf{F} = [F_1, \dots, F_{279}]$ 。




图 2 车门运动过程阶段划分

Fig. 2 Door movement stage division

针对门控器 I/O 信号的特点,采用基于多信号模型故障测试性分析的思想进行分析,通过测试生成车门亚健康依赖矩阵 \mathbf{D} 。对车门 I/O 信号数据进行离散化处理,提取 1 次开关门过程中所有 I/O 信号的跳变状态与跳变时间,组成的序对信息形式如下:

$$Z_j = \{(0, t_{j,1}), (0, t_{j,2}), (0, t_{j,3}), \dots, (0, t_{j,k})\} \quad (5)$$

式中:

Z_j ——门控器 I/O 信号参数;

j ——变量索引;

$t_{j,k}$ —— Z_j 的状态跳变时间;

k —— Z_j 的所有状态跳变次数。

将所有 I/O 变量跳变时刻 $t_{j,k}$ 选作测试点,生成测试区间 $[t_{j,k} - \Delta, t_{j,k} + \Delta]$ (Δ 为测试区间的时间间隔)。在每个测试区间内,对亚健康数据集进行测试, I/O 变量若发生正确的跳变,则将 \mathbf{D} 中对应元素赋值为 0,否则赋值为 1。通过测试得到开门与关门两个亚健康依赖矩阵,建立起车门 I/O 信号的触发时间、触发状态与车门亚健康状态之间的联系。

2.3 基本概率分配函数的构造

针对车门的电机数据与 I/O 信号,本文采用了不同的亚健康初步诊断方法,且其各自的决策层基本概率分配构造方法也不同。

电机数据基于 K-means 聚类相似度构造 BPA。对预处理后的车门电机数据特征值进行编号,应用 K-means 聚类算法进行分析,当聚类成功时将得到正常与亚健康两个聚类中心。根据两个聚类中心之间的特征值距离大小对特征进行排序,该特征值距离大的代表该特征在分类中作用明显,取排序前 20 个特征作为区分特征。为了对聚类结果进行识别,根据两类数据的特征大小对特征的编号标注

“正负号”(亚健康数据的特征相对正常数据变大时为“正号”,否则为“负号”)。通过计算测试数据区分特征与已知亚健康模型区分特征之间的相似度进行亚健康的模式识别与诊断。因此,基于 K-means 聚类结果构造 BPA 的计算式为:

$$m(A_i) = \frac{F(A_i)}{\sum_{i=1}^{2\theta} F(A_i)} \quad (6)$$

式中:

A_i ——车门可能发生的亚健康类型;

$F(A_i)$ ——测试数据的亚健康聚类结果与亚健康特征模型的相似度。

I/O 信号基于朴素贝叶斯分类构造 BPA。可将发生跳变的 I/O 信号量作为样本的属性,亚健康将矩阵中每个测试点的赋值结果作为样本对应属性的取值。基于属性条件独立性假设,贝叶斯推理的输出为每种亚健康发生的后验概率,而贝叶斯推理的先验概率可以通过训练数据的亚健康测试矩阵估计得到。假设每个 I/O 信号数据集中有 n 个开门数据、 m 个关门数据,对其进行贝叶斯分类后,将得到 n 个开门数据的亚健康推理结果与 m 个关门数据的推理结果,每个推理结果为 11 种亚健康发生的后验概率。本文将同一个数据集的开门与关门亚健康推理结果各自取平均值,最终每个数据集得到 1 个开门数据贝叶斯推理结果与 1 个关门数据贝叶斯推理结果。根据贝叶斯推理结果,构造 BPA 的计算方法^[7]如下:

$$m(c_j) = \frac{p(c_j | x_1, x_2, \dots, x_n)}{\sum_{j=1}^n p(c_j | x_1, x_2, \dots, x_n)} \quad (7)$$

式中:

$P(c_j)$ ——在已知属性为 x_1, x_2, \dots, x_n 的情况下,将其分类为 c_j 的概率。

2.4 车门亚健康融合诊断模型

基于 D-S 证据理论的车门亚健康诊断模型主要由 2 部分组成:① 第 1 部分是模型初步诊断层^[8],该层将预处理后的车门数据分别利用 K-means 聚类与贝叶斯推理得到初步的诊断结果,每种诊断结果将作为下一步决策层融合的证据;② 第 2 部分为模型的融合诊断层,根据电机数据与 I/O 信号的初步诊断结果构造各自的基本概率分配 m_1 、 m_2 ,应用 D-S 合成规则将其进行决策层融合得到新的基本概率分配,依据决策规则确定车门亚健康状

态。基于 D-S 证据理论的车门亚健康诊断模型如图 3 所示。




图 3 基于 D-S 证据理论的车门亚健康诊断模型

Fig. 3 Vehicle door sub-health diagnosis model based on D-S evidence theory

车门亚健康诊断模型的具体实施步骤为:

1) 确定识别框架。根据城市轨道交通车门系统发生的亚健康类型,采集 11 种车门亚健康状态的车门数据,建立识别框架 Θ 。

2) 数据预处理。按第 2.2 节的数据预处理方法对电机数据进行特征提取与标准化、离散性分析;对 I/O 数据进行结构化处理与测试分析生成亚健康依赖矩阵,每个亚健康状态数据集生成开门和关门亚健康依赖矩阵。

3) 构建基本概率分配函数。将电机与 I/O 信号测试数据输入到训练好的诊断模型中,得到各自的亚健康初步诊断结果。根据电机数据聚类结果计算特征相似度,利用式(6)构造基本概率分配函数 m_1 。基于 I/O 信号数据的开门与关门两个贝叶斯推理结果,利用式(7)计算 2 个基本概率分配结果,并将其进行一次 D-S 证据融合,将融合后的结果作为基本概率分配 m_2 。

4) 融合诊断。对步骤 3) 中计算得到的 2 个基本概率分配函数,根据式(4)的合成规则进行组合,得到车门最终的亚健康概率分配结果 m 。本文采用信度函数值最大原则进行亚健康判定,诊断的亚健康类型信任度必须为所有信任度的最大值 $F = \max(B_{el}(A_i))$ 。由于不考虑多种亚健康同时发生的情况,选择 BPA 最大的亚健康类型作为诊断结果。

3 车门亚健康融合诊断模型应用验证

以广州地铁 3 号线的塞拉门台架测试数据为例进行验证分析。为了进一步对其亚健康类型进行区分,在台架进行亚健康模拟时,将其细分成 11 种亚健康类型。采集的数据包含 1 组正常车门数据,11 组不同类型的亚健康数据,每组共包含 80 条数据(40 次开门数据与 40 次关门数据)。从每组亚健康数据中随机选择 60 次数据(30 次开门数据与 30

次关门数据)作为 1 个训练集,剩下的数据作为测试集,生成 11 个训练集与 11 个测试集。

3.1 车门亚健康状态识别框架

针对车门出现的 11 种亚健康类型,确定车门系统的识别框架 $\Theta = \{f_1, f_2, \cdots, f_{11}\}$ 。表 3 为车门亚健康状态识别框架。

表 3 车门亚健康状态识别框架

Tab.3 Vehicle door sub-health status recognition framework

亚健康类型	说明
f_1	对中 4.0 mm
f_2	对中 4.5 mm
f_3	对中 5.0 mm
f_4	V 型 7.0 mm
f_5	V 型 9.0 mm
f_6	V 型 12.0 mm
f_7	下挡销横向干涉
f_8	上滑道内调 3.5 mm
f_9	上滑道外调 3.0 mm
f_{10}	缓冲头磨损
f_{11}	压轮过松

3.2 车门亚健康状态初步诊断结果

对正常车门电机数据与未知的测试数据进行聚类分析,主要通过两个指标来判定车门发生的亚健康状态:一是聚类中心与亚健康训练模型,按照第 2.3 节的方法对特征编号标注“正负号”,正负相反的特征比例要求 <0.1 ;二是相同特征的比例要求 ≥ 0.6 ,当特征相似度超过 60% 时便认为可能会发生该种亚健康类型。表 4 为 11 个亚健康测试集的聚类诊断结果,每种亚健康类型测试集进行 5 次测试诊断,并对诊断结果取平均值。

根据表 4 中的诊断结果可以看出,电机数据基于 K -means 聚类能够对车门亚健康类型进行成功聚类,但是对聚类结果的识别诊断存在不确定性。例如,测试集 1、4、5 的聚类诊断结果出现了聚类中心,以及两种亚健康模式的特征相似度都超过 60% 的情况,表明两种亚健康都有可能发生,难以确定车门发生的真实亚健康类型。这种诊断结果不仅体现在同种类型的亚健康之间,测试集 1、5 的聚类诊断结果给出了两种亚健康模式 f_1 与 f_5 ,但是 f_1 为对中尺寸异常, f_5 为 V 型尺寸异常,属于不同的亚健康类别。对聚类结果进行模式识别时,如果为了

表 4 门控器 I/O 信号的 K -means 聚类诊断结果

Tab.4 K -means clustering diagnosis results of door controller I/O signals

测试集	实际亚健康类型	聚类诊断结果	平均特征相似度/%
1	f_1	f_1, f_5	93.62
2	f_2	f_2	75
3	f_3	f_3	88
4	f_4	f_4, f_6	60.53
5	f_5	f_1, f_5	59.68
6	f_6	f_6	72
7	f_7	f_7	77
8	f_8	识别失败	50
9	f_9	f_9	68
10	f_{10}	f_{10}	63
11	f_{11}	f_{11}	61

诊断结果尽可能准确而只提高对相同特征的比例要求,则会导致 f_9 、 f_{10} 、 f_{11} 出现如 f_8 无法识别的情况;而降低相同特征比例要求则会增加诊断结果的不确定性。

表 5 为 I/O 信号的贝叶斯诊断结果。对每个测试样本分配 1 个预测标签,将分类最多的类别标签作为测试数据的亚健康类型,以分类准确率评估诊断效果。

表 5 门控器 I/O 信号的贝叶斯诊断结果

Tab.5 Bayesian diagnosis results of door controller I/O signals

测试集	实际亚健康类型	贝叶斯诊断结果	分类准确率/%
1	f_1	f_1	100.00
2	f_2	f_2	50.00
3	f_3	f_3, f_5, f_{11}	33.00
4	f_4	f_{10}	31.80
5	f_5	f_3, f_5, f_{11}	33.00
6	f_6	f_3, f_5, f_{11}	0
7	f_7	f_{10}	9.50
8	f_8	f_8	63.63
9	f_9	f_9	50.00
10	f_{10}	f_{10}	68.18
11	f_{11}	f_3, f_5, f_{11}	33.00

根据表 5 中的诊断结果看出,I/O 信号基于贝叶斯对亚健康诊断的准确率平均值只有 42%,不如电机数据诊断结果理想; f_3 、 f_5 、 f_{11} 等 3 种亚健康模式的贝叶斯诊断结果相同且无法进行区分,而 f_6 、 f_7 出

现诊断错误情况。导致出现这样结果的原因为:目前城市轨道交通车门门控器采集的可用 I/O 信号量太少,且多数 I/O 信号量都与行程开关有关,能够区分的车门状态 I/O 信息不够全面,后续若能增加 I/O 数量将会增强其诊断能力。

3.3 车门亚健康状态融合诊断结果

在获取初步诊断结果后,通过式(6)一式(7)分

别计算 K -means 聚类与朴素贝叶斯的诊断结果对亚健康类型的基本概率分配结果,如表 6~7 所示。

对两个基本概率分配结果利用式(4)的 D-S 证据合成规则计算融合后得到基本概率分配,并依据信度最大原则确定最终的亚健康类型,诊断结果如表 8 所示。

表 6 基于 K -means 聚类的 BPA 计算结果
Tab.6 BPA calculation results based on K -means clustering

测试集	不同亚健康类型下的基本概率										
	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9	f_{10}	f_{11}
1	0.282 5	0.084 7	0.098 9	0.093 9	0.174 4	0.107 3	0.038 1	0.080 5	0.019 8	0	0.019 8
2	0.155 2	0.291 0	0.174 6	0.052 4	0.097 0	0.058 2	0.036 9	0.034 9	0.049 5	0.015 5	0.034 9
3	0.107 3	0.203 9	0.343 3	0.077 3	0.064 4	0.021 5	0.061 2	0.017 2	0.051 5	0.016 1	0.036 5
4	0.137 0	0.045 7	0.137 0	0.237 6	0.114 2	0.137 0	0.041 1	0.068 5	0.029 7	0.019 4	0.032 0
5	0.176 1	0.061 8	0.041 2	0.103 0	0.267 8	0.164 8	0.103 0	0.082 4	0	0	0
6	0.140 5	0.052 7	0	0.166 8	0.175 6	0.263 4	0.059 7	0.116 8	0.010 5	0.014 0	0
7	0.042 1	0.044 4	0.044 4	0.019 9	0.163 6	0.084 1	0.387 2	0.093 5	0.052 6	0.016 4	0.042 1
8	0.148 3	0.044 6	0.042 4	0.094 8	0.156 1	0.140 5	0.066 9	0.233 0	0.046 8	0	0.026 8
9	0.021 0	0.149 6	0.149 6	0.019 7	0	0	0.070 9	0.017 1	0.315 0	0.021 0	0.236 2
10	0.026 6	0.032 8	0.086 1	0.194 7	0	0.038 9	0.069 7	0.034 8	0.065 6	0.450 8	0
11	0.062 5	0.056 5	0.056 5	0.019 3	0.020 8	0.017 9	0.084 8	0.016 4	0.254 5	0.023 8	0.386 9

表 7 基于朴素贝叶斯的 BPA 计算结果
Tab.7 BPA calculation results based on naive Bayes

测试集	不同亚健康类型下的基本概率										
	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9	f_{10}	f_{11}
1	0.952 5	0	0	0.008 3	0	0	0.016 10	0.022 30	0.000 2	0.000 5	0
2	0.000 1	0.196 90	0.210 10	0	0.210 10	0.172 10	0	0	0	0	0.210 10
3	0	0.204 30	0.218 10	0	0.218 10	0.141 50	0	0	0	0	0.218 10
4	0.003 4	0	0	0.511 2	0	0	0.224 00	0.001 30	0.741 0	0.185 9	0
5	0	0.184 90	0.217 80	0	0.217 80	0.161 80	0	0	0	0	0.217 80
6	0	0.181 50	0.213 60	0.001 7	0.213 60	0.175 40	0.000 05	0	0	0	0.213 60
7	0.017 5	0	0	0.261 2	0	0	0.305 60	0.009 10	0.222 1	0.184 5	0
8	0.015 5	0.000 02	0	0.002 2	0	0	0.004 30	0.967 50	0.001 1	0.009 4	0
9	0.003 2	0.000 08	0.000 08	0.428 0	0.000 08	0.000 02	0.185 30	0.000 64	0.728 3	0.039 4	0.000 08
10	0.000 1	0	0	0.134 3	0	0	0.216 10	0.001 60	0.026 8	0.621 0	0
11	0	0.200 10	0.213 70	0	0.213 70	0.158 70	0	0	0	0	0.213 70

由表 6 可知,总体上电机数据基于 K -means 聚类的诊断结果准确性较高,但部分亚健康模型区分特征的差异性不够大,导致亚健康的基本概率分配值较低(0.2~0.4),整体的诊断结果可靠性较低。

表 7 开关门贝叶斯推理融合后的概率分配结果反映出,I/O 信号基于贝叶斯的诊断准确性较差,主要体现在对 f_3 、 f_5 、 f_{11} 等 3 种亚健康类型无法区分,但是对 f_1 、 f_8 、 f_9 、 f_{10} 等 4 种亚健康类型的诊断置信

表 8 融合诊断基本概率分配结果
Tab.8 Distribution results of fusion diagnosis basic probabilities

测试集	亚健康类型											诊断结果
	f ₁	f ₂	f ₃	f ₄	f ₅	f ₆	f ₇	f ₈	f ₉	f ₁₀	f ₁₁	
1	0.988 8	0	0	0.002 4	0	0	0.002 4	0.006 4	0.000 6	0	0	f ₁
2	0.000 8	0.401 2	0.324 6	0	0.177 1	0.041 0	0	0	0	0	0.056 1	f ₂
3	0	0.294 2	0.529 0	0	0.099 2	0.021 4	0	0	0	0	0.056 2	f ₃
4	0.003 8	0	0	0.882 9	0	0	0.057 9	0.000 2	0.012 9	0.042 3	0	f ₄
5	0	0.141 6	0.133 5	0	0.456 7	0.268 2	0	0	0	0	0	f ₅
6	0	0.000 1	0.105 6	0.003 0	0.414 2	0.475 7	0.000 4	0	0	0	0	f ₆
7	0.006 1	0	0	0.034 2	0	0	0.821 3	0.004 3	0.109 0	0.025 0	0	f ₇
8	0.008 3	0.000 7	0.000 2	0.000 8	0.000 6	0.000 5	0.001 8	0.988 0	0.000 3	0	0.000 1	f ₈
9	0.000 1	0.000 2	0.000 1	0.002 1	0	0	0.039 5	0.000 6	0.950 6	0.006 9	0.000 5	f ₉
10	0.000 2	0	0	0.087 3	0	0	0.050 9	0.000 5	0.003 0	0.858 7	0	f ₁₀
11	0	0.108 9	0.116 2	0	0	0	0	0	0	0	0.774 9	f ₁₁

度较高。

根据表 8 的融合诊断结果可知,融合模型对所有的测试集都能够进行准确诊断。在对测试集进行多次测试后,车门融合诊断模型的诊断准确率达到 90% 左右。融合后的亚健康诊断模型诊断性能要优于原有的单一诊断模型。与 *K*-means 聚类诊断模型相比,融合模型对亚健康的信任度分配更准确、更高而且更加集中,降低了亚健康模式之间的不确定性。与贝叶斯诊断模型相比,融合后的诊断模型能够对识别框架中所有的亚健康类型进行诊断并具有非常高的准确率。由此可见,D-S 证据理论能够有效地结合两种诊断模型的优点,弥补互相的不足,提高车门亚健康诊断模型的可靠性与准确性。

4 结语

针对城市轨道交通车辆车门系统在运营过程中处于亚健康工作状态的问题,提出了一种基于 D-S 证据理论的城市轨道交通车门亚健康诊断方法。该方法能够充分利用车门驱动电机数据与门控器 I/O 信号数据,并应用 *K*-means 聚类与贝叶斯推理的方法构建车门亚健康初步诊断模型。基于 D-S 证据理论在决策层进行信息融合,实现了车门亚健康状态的多层次、多模型诊断,提高了车门诊断结果的可靠性与准确性。通过车门数据仿真验证表明,本文的融合诊断方法能够充分利用车门可测量数据,弥补单一数据诊断模型的不足之处,具有实际应用价值。

参考文献

[1] 严俊,支有冉,许志兴,等. 随机森林在轨道交通车辆门系统亚健康状态诊断中的应用[J]. 城市轨道交通研究,2019 (12):114.

YAN Jun, ZHI Youran, XU Zhixing, et al. Application of random forest in the sub-health diagnose of railway vehicle door system[J]. Urban Mass Transit, 2019 (12):114.

[2] 陈苏雨,方宇,胡定玉. 基于随机森林方法的地铁车门故障诊断[J]. 测控技术,2018(2):20.

CHEN Suyu, FANG Yu, HU Dingyu. Subway door fault diagnosis based on random forest method[J]. Measurement and Control Technology, 2018(2):20.

[3] 施文,陆宁云,姜斌,等. 数据驱动的地铁车门微小故障智能诊断方法[J]. 仪器仪表学报,2019(6):192.

SHI Wen, LU Ningyun, JANG Bin, et al. Data-driven intelligent incipient fault diagnosis for subway vehicle door system[J]. Chinese Journal of Scientific Instrument, 2019 (6):192.

[4] 张妍,韩光威,陆宁云,等. 基于 JS 散度的轨道车辆门系统健康状态评估方法[J]. 机械设计与制造工程,2017(11):122.

ZHANG Yan, HAN Guangwei, LU Ningyun, et al. Railway vehicle door system health status based on JS divergence[J]. Mechine Design and Manufacturing Engineering, 2017 (11):122.

[5] 李晗,萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011(1):1.

LI Han, XIAO Deyun. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011(1):1.

[6] 高文明,李志保,唐谦,等. 轨道车辆门远程监控与故障诊断系统软件设计[J]. 机械设计与制造工程,2016(10):49.

(下转第 69 页)