

文章编号: 2095-2163(2023)04-0069-09

中图分类号: TP391

文献标志码: A

# 基于模糊逻辑的车载终端分层故障检测模型

陈家超, 陈庆奎

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

**摘要:** 为尽早发现车载终端故障,提升设备检测效率,提出一种基于模糊逻辑的分层故障检测模型。该模型将传感数据的异常或丢失作为证据,车辆或设备的异常工作状态作为现象,通过证据、现象和故障之间的累计变化规律实现车载终端故障检测。首先,统计时间片段中若干种证据,并计算证据累计度。然后,对证据累计度设置关联权重,结合模糊逻辑实现规则匹配与现象推导。最后,根据现象反馈动态修正规则。若干种现象实现故障推导和规则修正的过程同理。理论分析与实践结果表明,所提模型能够有效检测车载终端故障。

**关键词:** 车载终端; 分层故障检测; 累计度; 模糊逻辑; 动态修正

## Hierarchical fault detection model of vehicle terminal based on fuzzy logic

CHEN Jiachao, CHEN Qingkui

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**[Abstract]** In order to find vehicle terminal faults and improve device detection efficiency, a hierarchy fault detection model based on fuzzy logic is proposed. In this model, the vehicle terminal faults are detected according to the cumulative change law between the evidence, phenomenon and fault, in which the evidence refers to the abnormality or loss of sensing data and the phenomenon refers to the abnormal working condition of vehicles or equipments. First of all, the cumulative degree of evidence is calculated by counting the number of several kinds of evidences. Then, the association weight is set for the cumulative degree of evidence, and the rule matching and phenomenon derivation are realized combined with fuzzy logic. Finally, the rules are dynamically modified according to the phenomenon feedback. The process of several phenomena realizing fault derivation and rule correction is the same as the above. According to the theoretical analysis and practical results, it is verified that the proposed model can effectively detect the vehicle terminal fault.

**[Key words]** vehicle terminal; hierarchical fault detection; cumulative degree; fuzzy logic; dynamic correction

## 0 引言

随着信息化产业快速发展,智能设备的规模不断增长、集成化水平也在提升,故障发生已然成为一种常态<sup>[1]</sup>,例如无人机传动器故障<sup>[2]</sup>、铁路牵引器故障<sup>[3]</sup>、同步发电机滤波器故障<sup>[4]</sup>等。车载终端是提供车辆位置信息、视频监控等功能的智能设备<sup>[5]</sup>,由于设备运作时间长,且经常受到车辆行驶颠簸等环境因素的影响,其内部功能模块容易产生损耗,从而引发故障,例如:定位模块故障、4G 模块故障等。

本文将车载终端传感数据的异常或丢失作为证据,行车异常事件作为现象,建立包含证据、现象和故障的分层模型。传感数据易受信号干扰,为了减少故障误报,保证模型的容错能力,结合模糊逻辑与累计度变化规律构建知识库,通过知识库中的规则<sup>[6-7]</sup>实现由若干种证据累计形成现象、再由若干种现象累计形成故障的推导过程,从而有效检测车载终端故障。考虑到根据专家经验设置的规则初始参数存在估计偏差,在模型运行过程中采用修正算法动态调节参数,进一步提升模型的可靠性。

**基金项目:** 国家自然科学基金(61572325);上海重点科技项目(19DZ1208903);上海智能家居大规模物联共性技术工程中心项目(GCZX14014)。

**作者简介:** 陈家超(1997-),男,硕士研究生,主要研究方向:模糊理论、数据分析;陈庆奎(1966-),男,博士,教授,博士生导师,CCF高级会员,主要研究方向:计算机集群、人工智能、并行理论、物联网大规模数据分析等。

**通讯作者:** 陈庆奎 Email: chenqingkui@usst.edu.cn

收稿日期: 2022-05-12

现阶段,工人仍然采用定期巡检的方式来维护车载终端,导致故障发现不及时,整体检测效率较低,该模型减少了工人巡检大批设备所需的工作量,能够可靠检测设备故障,因此具有重要的实际意义。

## 1 相关工作

模糊逻辑与传统二值逻辑相比,更符合人对客观事物的思维认知,能够针对具备模糊不确定性概念的问题给出有效解决方法,在故障检测及故障诊断领域中被广泛使用。文献[8]提出一种基于模糊逻辑的输电网络定向接地故障检测方法,将电压测量数据匹配模糊规则,从而实现故障分类检测。文献[9]提出一种基于直觉模糊脉冲神经 P(IFSNP) 系统的设计方法,能够有效诊断电力系统中复杂故障的成因。文献[10]提出一种融合多尺度模糊熵的特征提取方法,实现了旋转机械的轴承故障诊断。文献[11]针对道路施工装备存在故障人工处理难度大、成本高等问题,采用 T-S 模糊故障树实现了基于 GPRS 网络的远程故障诊断系统及方法。文献[12]提出一种将多分辨率分析与模糊-ARTMAP 神经网络相结合的方法,实现了电气设备故障的检测及分类。文献[13]提出一种神经网络与模糊 PID

控制相结合的方法,从控制角度定位自动驾驶车辆的执行器故障。

本文的故障检测模型区别于上述文献,通过对证据、现象和故障三种事件类型进行定义,采用累计的方式实现模型分层推导,并以此检测车载终端故障,其特点包括:

(1) 具有包含证据、现象和故障的分层结构,相比神经网络的“黑箱”模型<sup>[14]</sup>,整个故障推导过程更加清晰,可解释性更强。

(2) 针对若干种证据形成现象、若干种现象形成故障的变化规律,根据不同时间粒度实现累计,使故障检测过程更具层次性。

(3) 结合反馈结果修正模型参数,通过运行时参数的不断优化,提升了模型的可靠性。

## 2 分层故障检测模型

分层故障检测模型的总体结构如图 1 所示。首先,对时间段内的若干种证据进行累计,并计算相应的证据累计度;其次,为证据累计度设置关联权重,匹配证据-现象规则并推导现象;然后,结合现象反馈动态修正证据-现象规则;最后,通过若干种现象同理推导故障,并动态修正现象-故障规则。

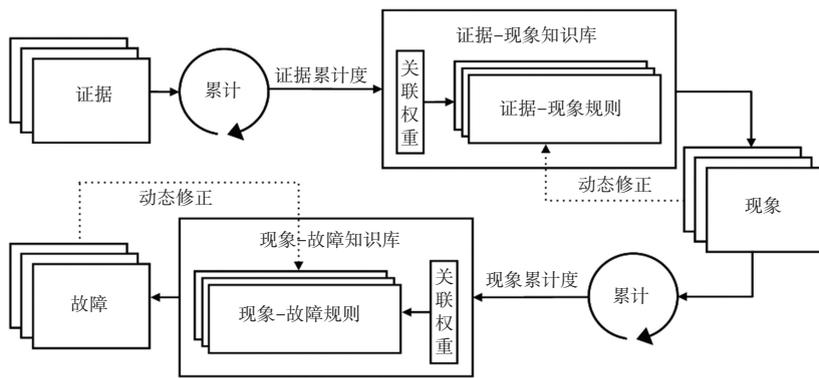


图 1 分层故障检测模型总体结构

Fig. 1 Overall structure of layered fault detection model

### 2.1 分层模型事件

分层模型包含若干种事件,例如:GPS 定位数据异常、车辆不定位、定位器模块故障等。按不同事件类型将其分为证据、现象和故障。对此拟做阐释分述如下。

(1) 证据:车载终端提供多种传感数据,且不同类型数据具备相应的传输协议,当数据不满足协议传输标准时产生证据。证据按性质可分为异常类证据和丢失类证据,前者表示传感数据不符满足协议约定的数值范围,后者表示传感数据不满足协议约

定的数据传输频次。例如:协议标准要求 GPS 定位数据不能超过行驶线路  $s$  m 的范围外,若当前 GPS 定位数据超出该范围,形成“GPS 定位数据异常”证据;协议标准要求每  $t$  s 完成一次通讯链路数据上传,若远端未能在规定时间内接收到该数据,形成“通讯链路数据丢失”证据。

(2) 现象:现象表示车辆或设备的异常工作状态,例如:车辆定位漂移、视频监控图像闪烁等。若干种证据频繁出现时可以说明现象产生。例如:“GPS 定位数据异常”证据和“通讯链路数据丢失”证据频

繁出现时,可以说明“车辆定位漂移”现象产生。

(3)故障:车载终端包含多个传感模块,例如:定位模块、通讯模块等。若干种现象频繁出现时可以说明故障产生。例如:“车辆定位漂移”现象和“车辆不定位”现象频繁产生时,可以说明“定位模块”故障产生。

## 2.2 累计度计算

累计度表示时间片段中同一事件的累计数量程度,根据事件的不同类型,分为证据累计度和现象累计度。

设时间片段  $W$  大小为  $p$ , 证据类别数为  $n$ , 对于第  $j$  种证据  $C_j (1 \leq j \leq n)$ , 建立累计窗口  $SW_j$ , 并将  $W$  划分为  $q$  个等长子片段,  $SW_j = \{s_{j,t_a}, s_{j,t_{a+1}}, \dots, s_{j,t_{a+q}}\} (a \geq 1)$ , 其中  $t_a$  表示  $W$  中的第  $a$  个子片段 ( $1 \leq a \leq q$ ),  $s_{j,t_a}$  表示  $t_a$  中证据  $C_j$  的产生标志, 若证据  $C_j$  产生,  $s_{j,t_a} = 1$ ; 否则  $s_{j,t_a} = 0$ 。统计  $SW_j$  中  $q$  个子片段的证据产生标志, 可知证据  $C_j$  的总累计数。在长度为  $p$  的时间范围内, 根据专家经验估计证据  $C_j$  的总累计数  $\lambda_{j,p}$ , 记证据  $C_j$  对应的累计度为  $c_j$ ,  $SW_j$  中  $c_j$  的计算方法如式(1)所示:

$$c_j = \frac{\text{sum}(SW_j)}{\lambda_{j,p}} \quad (1)$$

其中,  $\text{sum}$  表示  $SW_j$  中所有  $s_{j,t_q}$  的数值总和。

车载终端传感数据具备时效性,  $SW_j$  中证据的产生标志随着时间片段变化不断更新, 证据累计度亦不断更新。若初始状态下  $SW_j = \{s_{j,t_1}, s_{j,t_2}, \dots, s_{j,t_q}\}$ , 在当前时刻超出子片段  $t_q$  作用的时间范围时, 第  $t_1$  个子片段中证据  $C_j$  的产生标志  $s_{j,t_1}$  失效, 同时形成第  $t_{q+1}$  个子片段, 对应证据  $C_j$  的产生标志  $s_{j,t_{q+1}}$ , 此时  $SW_j$  更新为  $\{s_{j,t_2}, s_{j,t_3}, \dots, s_{j,t_{q+1}}\}$ 。累计窗口  $SW_j$  在时间轴上的位置动态变化, 其不断移动的过程实现了证据累计度的连续计算。

通过统计时间片段中的现象产生标志可以完成现象累计度的连续计算, 其计算方法和累计窗口更新过程同理。

## 2.3 知识库结构及规则推导

### 2.3.1 知识库结构

知识库是用于表示事件之间关联的集合<sup>[15]</sup>, 对于证据、现象和故障三种事件, 集合包含了证据与现象, 以及现象与故障之间的多对多关联及对应关联的强弱。

证据与现象之间存在多对多关联, 在表1证据与现象的示例中, “GPS定位数据异常”证据和“通讯链路数据丢失”证据可能与“车辆定位漂移”现象

有关, 也可能与“车辆不定位”现象有关。证据与现象之间存在关联强弱, 例如: “GPS定位数据异常”证据与“通讯链路数据丢失”证据相比, 前者对“车辆定位漂移”现象的关联更强, 而后者对“车辆不定位”现象的关联更强。

表1 证据与现象示例

Tab. 1 Evidence and phenomenon samples

证据	现象
GPS定位数据异常	车辆定位漂移
通讯链路数据丢失	车辆不定位

记证据和现象的类别数分别为  $n$  和  $m$ , 对于第  $j$  种证据  $C_j$  与第  $i$  种现象  $D_i (1 \leq j \leq n, 1 \leq i \leq m)$ , 采用关联权重  $\alpha_{i,j}$  来表示证据  $C_j$  与现象  $D_i$  之间的关联强弱, 其满足约束条件  $\sum_{j=1}^m \alpha_{i,j} = 1, \alpha_{i,j}$  越大表示关联越强, 反之亦然。当  $\alpha_{i,j} = 0$  时, 说明证据  $C_j$  与现象  $D_i$  之间不存在关联; 当  $0 < \alpha_{i,j} < 1$  时, 说明证据  $C_j$  与现象  $D_i$  之间存在关联; 当  $\alpha_{i,j} = 1$  时, 说明证据  $C_j$  与现象  $D_i$  之间是唯一关联。

若干种证据通过累计形成现象, 当证据累计度不足时, 对应现象无法产生, 例如: “GPS定位数据异常”证据与“通讯链路数据丢失”证据的累计度都很低时, 说明证据没有频繁出现, 该情况下现象不会产生。根据式(1)中证据累计度  $c_j$  的计算方法, 当  $SW_j$  中证据  $C_j$  的产生数量和专家估计值相同时, 标准累计度值为 1, 此时证据  $C_j$  相对于现象  $D_i$  的标准加权累计度可以直接表示为  $\alpha_{i,j}$ 。累计度并不是精确的、固定的, 其取值大小具备模糊不确定性<sup>[16-17]</sup>, 即累计度可能稍高, 也可能稍低。记  $b_{i,j}$  为  $\alpha_{i,j}$  的初始中心偏移量,  $\tilde{\alpha}_{i,j}$  为加权累计度阈值区间,  $\tilde{\alpha}_{i,j} = [\alpha_{i,j} - b_{i,j}, \alpha_{i,j} + b_{i,j}]$ 。证据-现象规则结构如式(2)所示:

$$\tilde{\alpha}_{i,1} C_1 \oplus \tilde{\alpha}_{i,2} C_2 \oplus \dots \oplus \tilde{\alpha}_{i,n} C_n = \omega_i D_i \quad (2)$$

其中, “ $\oplus$ ”表示若干个证据条件项之间的“与”关系,  $\omega_i$ 表示现象  $D_i$  产生的可能性, 即现象  $D_i$  的可信度, 其满足  $0 < \omega_i \leq 1$ 。

记  $\hat{\alpha}_{i,j}$  为证据  $C_j$  相对于现象  $D_i$  的加权累计度,  $\hat{\alpha}_{i,j} = \alpha_{i,j} * c_j$ 。当  $\hat{\alpha}_{i,j}$  落在加权累计度阈值区间  $\tilde{\alpha}_{i,j}$ , 即  $\hat{\alpha}_{i,j} \in \tilde{\alpha}_{i,j}$  时, 则表示  $\hat{\alpha}_{i,j}$  隶属于  $\tilde{\alpha}_{i,j}, \tilde{\alpha}_{i,1}, \tilde{\alpha}_{i,2}, \dots, \tilde{\alpha}_{i,n}$  分别在  $[0, 1]$  内实现范围划分, 从而达到隶属区间离散化的目的。对于  $m$  种现象, 若干条证据-现象规则组成了证据-现象知识库, 其结构采用增广矩阵表达式  $\mathbf{R}_{m \times (n+1)}$  来定义, 具体见式(3):

$$R_{m \times (n+1)} = \begin{bmatrix} \bar{\alpha}_{1,1} & \bar{\alpha}_{1,2} & \cdots & \bar{\alpha}_{1,n} & \omega_1 \\ \bar{\alpha}_{2,1} & \bar{\alpha}_{2,2} & \cdots & \bar{\alpha}_{2,n} & \omega_2 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \bar{\alpha}_{m,1} & \bar{\alpha}_{m,2} & \cdots & \bar{\alpha}_{m,n} & \omega_m \end{bmatrix} \quad (3)$$

现象与故障之间存在多对多关联,在表2现象与故障的示例中,“车辆定位漂移”现象和“车辆不定位”现象可能与“定位模块”故障有关,也可能与“4G模块”故障有关。现象与故障之间存在关联强弱,例如:“车辆定位漂移”现象与“车辆不定位”现象相比,前者对“定位模块”故障的关联更强,而后者对“4G模块”故障的关联更强。

表2 现象与故障示例

Tab. 2 Phenomenon and fault samples

现象	故障
车辆定位漂移	定位模块
车辆不定位	4G模块

现象-故障知识库由若干条现象-故障规则组成,其结构与证据-现象知识库同理。

### 2.3.2 规则推导

若干种证据计算加权累计度后匹配证据-现象规则。当 $n$ 种证据的加权累计度 $\hat{\alpha}_{i,1}, \hat{\alpha}_{i,2}, \dots, \hat{\alpha}_{i,n}$ 分别隶属于加权累计度阈值区间 $\bar{\alpha}_{i,1}, \bar{\alpha}_{i,2}, \dots, \bar{\alpha}_{i,n}$ 时,认为该规则的条件生效,得到 $\omega_i$ 可信度的现象 $D_i$ 。在证据-现象知识库中, $\hat{\alpha}_{i,1}, \hat{\alpha}_{i,2}, \dots, \hat{\alpha}_{i,n}$ 存在使多条规则同时生效的情况,进而导致多种现象同时形成。设置数量阈值 $e(1 \leq e \leq m)$ ,表示选取最可能产生的 $e$ 种现象。由于证据累计度的浮动偏差会影响现象实际产生的可能性。记第 $i$ 种现象的加权可信度为 $\hat{\omega}_i$ , $\bar{\alpha}_{i,j}$ 的区间上限为 $sup(\bar{\alpha}_{i,j})$ ,区间下限为 $inf(\bar{\alpha}_{i,j})$ 。 $\hat{\alpha}_{i,j}$ 越接近 $sup(\bar{\alpha}_{i,j})$ ,说明现象 $D_j$ 越可能产生,对应 $\hat{\omega}_i$ 的取值也就越大。将 $\hat{\alpha}_{i,j}$ 的重要度记作 $\beta_{i,j}$ , $\beta_{i,j}$ 的计算方法可写为如下公式:

$$\beta_{i,j} = \frac{\hat{\alpha}_{i,j} - inf(\bar{\alpha}_{i,j})}{sup(\bar{\alpha}_{i,j}) - inf(\bar{\alpha}_{i,j})} \quad (4)$$

将若干个 $\hat{\alpha}_{i,j}$ 与 $\beta_{i,j}$ 的乘积之和作为 $\omega_i$ 的加权系数计算 $\hat{\omega}_i$ ,推得的公式为:

$$\hat{\omega}_i = \omega_i * \sum_{j=1}^n (\beta_{i,j} * \hat{\alpha}_{i,j}) \quad (5)$$

对于 $\hat{\omega}_1, \hat{\omega}_2, \dots, \hat{\omega}_m$ ,按大小由高至低排序,选取其中前 $e$ 种现象作为规则推导的结果。通过现象加权累计度匹配现象-故障规则的方式可以实现故

障推导。在产生多种故障结果时,根据加权可信度高低选取若干种最可能发生的故障,其过程同理。

## 2.4 规则动态修正

模型初始建立时,规则中加权累计度阈值区间 $\bar{\alpha}_{i,j}$ 是结合专家经验得出的先验参数,专家无法提前获知实际运行过程中加权累计度 $\hat{\alpha}_{i,j}$ 的分布,因此通过 $\hat{\alpha}_{i,j}$ 与结果反馈来动态修正 $\bar{\alpha}_{i,j}$ ,减少人为估计带来的偏差,提升模型可靠性。根据结果反馈, $\hat{\alpha}_{i,j}$ 分为正常分布点和异常分布点。当规则的条件生效时,所谓正常分布点是指规则推导结果与专家实际确认结果相符时的 $\hat{\alpha}_{i,j}$ ,而异常分布点是指规则推导结果与专家实际确认结果不符时的 $\hat{\alpha}_{i,j}$ 。根据正常分布点和异常分布点的位置,动态修正阈值区间 $\bar{\alpha}_{i,j}$ ,修正方法分为3种:扩张法、收缩法和平移法。具体如下。

(1)扩张法。用于增大加权累计度分布点覆盖范围,提升规则适用性,即保持覆盖范围中心不变,减小 $inf(\bar{\alpha}_{i,j})$ 的同时增大 $sup(\bar{\alpha}_{i,j})$ ,如图2所示;但若 $\bar{\alpha}_{i,j}$ 覆盖范围过大,则会掺杂较多的异常分布点,导致规则准确性降低。

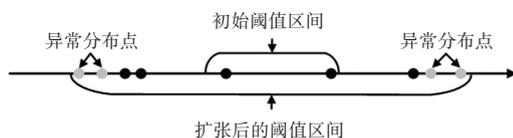


图2 采用扩张法修正阈值区间

Fig. 2 Using expansion method to modify the threshold interval

(2)收缩法。用于减小加权累计度分布点覆盖范围,提升规则准确性,即保持覆盖范围中心不变,增大 $inf(\bar{\alpha}_{i,j})$ 的同时减小 $sup(\bar{\alpha}_{i,j})$ ,如图3所示;但若 $\bar{\alpha}_{i,j}$ 覆盖范围过小,则会遗漏较多的正常分布点,导致规则适用性降低。

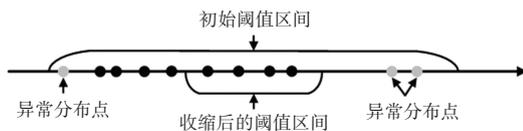


图3 采用收缩法修正阈值区间

Fig. 3 Using shrinkage method to modify the threshold interval

(3)平移法。由于加权累计度 $\hat{\alpha}_{i,j}$ 可能存在集中于数轴单侧的情况,扩张法和收缩法无法有效调整阈值区间,采用平移法更新覆盖范围中心,如图4所示。根据 $\hat{\alpha}_{i,j}$ 的实际分布情况,该方法可以对中心点选择左移或右移,即保持 $inf(\bar{\alpha}_{i,j})$ 与 $sup(\bar{\alpha}_{i,j})$ 之间的距离不变,以相同幅度同时增大 $inf(\bar{\alpha}_{i,j})$ 及

$sup(\tilde{\alpha}_{i,j})$ , 或同时减小  $inf(\tilde{\alpha}_{i,j})$  及  $sup(\tilde{\alpha}_{i,j})$ 。

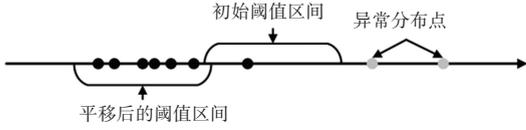


图 4 平移法修正阈值区间

Fig. 4 Using translation method to modify the threshold interval

现以证据-现象规则为例, 根据 3 种阈值区间修正方法, 给出加权累计度阈值区间  $\tilde{\alpha}_{i,j}$  的修正算法迭代步骤:

**Step 1** 首先, 将区间  $[0, 1]$  等分为  $r$  段, 每个子区间的大小为  $\varepsilon, \varepsilon = \frac{1}{r}$ , 将其作为区间单侧扩张或收缩的步长。然后, 在各子区间中初始化区间计数器  $tcnt$ 、 $fcnt$  及循环计数器  $qnt$ , 初始值均为 0。将第  $k(1 \leq k \leq r)$  个子区间对应  $tcnt$ 、 $fcnt$  记作  $tcnt_k, fcnt_k$ 。其中,  $tcnt_k$  用于统计正常分布点命中了第  $k$  个子区间的次数;  $fcnt_k$  用于统计异常分布点命中了第  $k$  个子区间的次数。最后, 建立集合  $S$  存放  $\hat{\alpha}_{i,j}$  中的正常分布点, 执行 Step 2。

**Step 2** 根据累计窗口  $SW$  计算若干种证据的累计度, 并根据加权累计度匹配证据-现象规则。当通过规则推导出现象时,  $qnt = qnt + 1$ , 同时由专家确认该现象是否实际发生。若实际发生, 将该  $\hat{\alpha}_{i,j}$  添加到集合  $S$  中, 若其对应第  $k$  个子区间,  $tcnt_k = tcnt_k + 1$ ; 若实际未发生,  $fcnt_k = fcnt_k + 1$ 。由于初始状态下  $\hat{\alpha}_{i,j}$  的个数较少, 无法有效估计点位分布情况, 因此重复执行 Step 2, 直到  $qnt$  满足迭代启动阈值  $QTHRESHOLD$ , 执行 Step 3。

**Step 3** 假设当前  $\tilde{\alpha}_{i,j} = [h_s, h_l]$ , 分别对  $\tilde{\alpha}_{i,j}$  覆盖范围下的若干个  $tcnt$  和  $fcnt$  求和。若  $\frac{sum(tcnt)}{sum(tcnt) + sum(fcnt)} > \omega_i$ , 说明  $\tilde{\alpha}_{i,j}$  的覆盖范围较小, 采用扩张法增大覆盖范围, 执行 Step 4; 若  $\frac{sum(tcnt)}{sum(tcnt) + sum(fcnt)} < \omega_i$ , 说明  $\tilde{\alpha}_{i,j}$  的覆盖范围较大或覆盖范围中心偏离, 执行 Step 5; 若  $\frac{sum(tcnt)}{sum(tcnt) + sum(fcnt)} = \omega_i$ , 执行 Step 8。

**Step 4** 以  $\varepsilon$  的步长扩张区间上下限, 扩张后阈值为  $[h_s - \varepsilon, h_l + \varepsilon]$ , 且满足约束条件  $h_s - \varepsilon \geq 0, h_l + \varepsilon \leq 1$ 。然后, 执行 Step 8。

**Step 5** 在左半区间  $[h_s, \frac{h_s + h_l}{2}]$  和右半区间

$[\frac{h_s + h_l}{2}, h_l]$  中分别统计  $sum(tcnt)$ , 记作  $lsum(tcnt)$  和  $rsum(tcnt)$ 。若  $\frac{lsum(tcnt)}{rsum(tcnt)} \geq T$  或

$\frac{rsum(tcnt)}{lsum(tcnt)} \geq T$  时, 说明正常分布点主要集中在区间左侧或右侧, 采用平移法更新  $\tilde{\alpha}_{i,j}$  的覆盖范围中心, 执行 Step 6, 其中  $T$  表示比例阈值,  $T$  越接近 1, 说明  $\hat{\alpha}_{i,j}$  分布越均匀; 若  $\frac{lsum(tcnt)}{rsum(tcnt)} \leq T$  且  $\frac{rsum(tcnt)}{lsum(tcnt)} \leq T$  时, 说明正常分布点并未出现左偏或右偏的情况, 采用收缩法减小覆盖范围, 执行 Step 7。

**Step 6** 在集合  $S$  中查找隶属于当前  $\tilde{\alpha}_{i,j}$  的若干个分布点  $\hat{\alpha}_{i,j}$ , 并计算覆盖范围中心, 记  $S = \{\hat{\alpha}_{i,j,1}, \hat{\alpha}_{i,j,2}, \dots, \hat{\alpha}_{i,j,u}\}$ , 更新后的中心点为  $\frac{\sum_{s=1}^u \hat{\alpha}_{i,j,s}}{u}$ , 平移后的阈值为  $[\frac{h_s - h_l}{2} + \frac{\sum_{s=1}^u \hat{\alpha}_{i,j,s}}{u}, \frac{h_l - h_s}{2} + \frac{\sum_{s=1}^u \hat{\alpha}_{i,j,s}}{u}]$ , 且满足约束条件  $\frac{h_s - h_l}{2} + \frac{\sum_{s=1}^u \hat{\alpha}_{i,j,s}}{u} \geq 0, \frac{h_l - h_s}{2} + \frac{\sum_{s=1}^u \hat{\alpha}_{i,j,s}}{u} \leq 1$ 。然后, 执行 Step 8。

**Step 7** 以  $\varepsilon$  的步长收缩区间上下限, 收缩后的阈值为  $[h_s + \varepsilon, h_l - \varepsilon]$ , 且满足约束条件  $h_s + \varepsilon \leq h_l - \varepsilon$ 。然后, 执行 Step 8。

**Step 8** 将循环计数器  $qnt$  置为 0, 本轮  $\tilde{\alpha}_{i,j}$  修正结束, 开始下一轮迭代, 执行 Step 2。

在现象-故障规则中, 加权累计度阈值区间  $\tilde{\alpha}_{i,j}$  通过现象加权累计度  $\hat{\alpha}_{i,j}$  及故障反馈结果来实现修正, 其修正算法执行步骤同理。

### 3 实验分析

#### 3.1 实验数据集及准备工作

##### 3.1.1 实验数据集

实验数据集由某车载终端公司提供, 包含 100 台车载终端的 300 日历史数据, 数据类别有: GPS 数据、到离站数据、通讯链路数据和 DVR 数据。表 3、表 4 和表 5 分别就不同数据类别给出证据、现象和故障的实例。

表3 证据实例

Tab. 3 Evidence examples

符号	证据
$X_1$	GPS 定位数据异常
$X_2$	GPS 定位数据丢失
$X_3$	通讯链路数据丢失
$X_4$	到离站数据异常
$X_5$	视频移动侦测数据异常
$X_6$	视频状态数据丢失

表4 现象实例

Tab. 4 Phenomenon examples

符号	现象
$Y_1$	车辆定位漂移
$Y_2$	车辆不定位
$Y_3$	视频监控图像闪烁
$Y_4$	视频监控无图像

表5 故障实例

Tab. 5 Fault examples

符号	故障
$Z_1$	定位模块
$Z_2$	4G 模块
$Z_3$	DVR 模块

### 3.1.2 准备工作

这里,结合专家经验初始化证据-现象知识库和现象-故障知识库中若干条规则的标准加权累计度和中心偏移量,参数见表6、表7,表6、表7的每行代表规则,其中 $\alpha_i (1 \leq i \leq 6)$ 表示规则中第 $i$ 个条件项对应的初始权重, $\omega$ 表示可信度。初始权重的中心偏移量 $b$ 均设置0.1。以表7中的现象-故障知识库中的规则 No.1 为例,即表示当“车辆定位漂移”现象的加权累计度在0.3~0.5范围内,且“车辆不定位”现象的加权累计度在0.5~0.6范围内时,产生“定位模块”故障的可信度为0.8。

表6 证据-现象知识库初始参数

Tab. 6 Evidence-phenomenon knowledge base initial parameters

No.	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\alpha_5$	$\alpha_6$	$\omega$
1	0.4	0.2	0.1	0.3	0	0	0.8
2	0.2	0.3	0.3	0.2	0	0	0.9
3	0	0	0.4	0	0.2	0.4	0.8
4	0	0	0.3	0	0.4	0.3	0.9

表7 现象-故障知识库初始参数

Tab. 7 Phenomenon-fault knowledge base initial parameters

No.	$\alpha_1$	$\alpha_2$	$\alpha_3$	$\alpha_4$	$\omega$
1	0.4	0.6	0	0	0.8
2	0.2	0.3	0.2	0.3	0.8
3	0	0	0.4	0.6	0.8

## 3.2 评价指标

### 3.2.1 区间偏差率

区间偏差率是衡量阈值区间修正前后偏差程度的单位。记初始阈值区间为 $[a, b]$ ,修正后的阈值区间为 $[c, d]$ 。阈值下限偏差 $LB$ 、阈值上限偏差 $HB$ 的计算方法可用式(6)、式(7)来表示:

$$LB = \begin{cases} \frac{c-a}{1-a} & a < c \leq 1 \\ 0 & a = c \\ \frac{a-c}{a} & 0 \leq c < a \end{cases} \quad (6)$$

$$HB = \begin{cases} \frac{d-b}{1-b} & b < d \leq 1 \\ 0 & b = d \\ \frac{b-d}{b} & 0 \leq d < b \end{cases} \quad (7)$$

根据 $LB$ 和 $HB$ 计算区间偏差率 $BR$ ,研究推得公式为:

$$BR = \frac{LB + HB}{2} \times 100\% \quad (8)$$

### 3.2.2 查准率和查全率

模型的可靠性通过知识库中规则的查准率 $PC$ 和查全率 $RC$ 来体现。对于证据-现象知识库,其评价指标具体描述如下:

车辆从起点场站行驶至终点场站的时间片段称为全程。将车载终端历史数据按全程进行划分,设全程数为 $M$ ,现象类别数为 $N$ ,对于第 $i$ 次全程中的第 $j$ 种现象( $1 \leq i \leq M, 1 \leq j \leq N$ ), $\gamma_{i,j}$ 表示规则推导出的现象结论。当通过规则得出现象时, $\gamma_{i,j} = 1$ ,否则 $\gamma_{i,j} = 0$ ; $\hat{\gamma}_{i,j}$ 表示实际的现象结论,当实际现象存在时, $\hat{\gamma}_{i,j} = 1$ ,否则 $\hat{\gamma}_{i,j} = 0$ 。

真正例 $TP$ 、假正例 $FP$ 、假反例 $FN$ 和真反例 $TN$ 的计算方法的数学公式可写为:

$$A = \sum_{j=1}^N \sum_{i=1}^M A_{i,j} \quad (9)$$

其中, $A \in \{TP, FP, FN, TN\}$ 。当 $\gamma_{i,j} = 1$ 且 $\hat{\gamma}_{i,j} = 1$ 时, $TP_{i,j} = 1$ ;当 $\gamma_{i,j} = 1$ 且 $\hat{\gamma}_{i,j} = 0$ 时,

$FP_{i,j} = 1$ ; 当  $\gamma_{i,j} = 0$  且  $\hat{\gamma}_{i,j} = 1$  时,  $FN_{i,j} = 1$ ; 当  $\gamma_{i,j} = 0$  且  $\hat{\gamma}_{i,j} = 0$  时,  $TN_{i,j} = 1$ 。平均查准率和查全率的计算方法可用式(10)、式(11)进行描述:

$$PC = \frac{TP}{TP + FP} \quad (10)$$

$$RC = \frac{TP}{TP + FN} \quad (11)$$

对于现象-故障知识库, 将车载终端历史数据按日进行划分, 其评价指标的计算方法同理。

### 3.3 实验结果

实验涉及 4 种现象和 3 种故障, 对于多条证据-现象规则同时生效时的数量阈值  $e$ , 将  $e$  设置为 4, 表示选取所有可能产生的现象; 对于现象-故障规则, 将  $e$  设置为 1, 表示只选取最可能产生的故障。经过前期测试, 加权累计度阈值区间  $\tilde{\alpha}_{i,j}$  的子区间大小  $\varepsilon$  设置为 0.01, 比例阈值  $T$  设置为 2, 即两侧分布点在呈现 2 倍数量差时认为出现了左偏或右偏。

根据 60 台车载终端的 300 日历史数据, 分别以证据-现象规则 No.1 和现象-故障规则 No.1 为例, 当  $\alpha_{i,j} \neq 0$  时 ( $\alpha_{i,j}$  即规则 No.  $j$  对应的  $\alpha_i$ ), 给出 2 种规则在 20 次迭代过程中加权累计度阈值区间  $\tilde{\alpha}_{i,j}$  的修正过程, 图 5~ 图 8 展示了证据-现象规则 No.1 中各条件项对应阈值区间的变化。

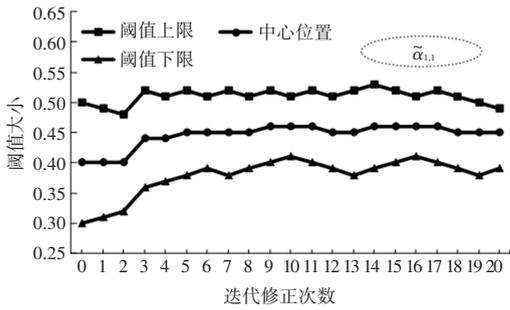


图 5 证据-现象规则 No.1 的  $\tilde{\alpha}_{1,1}$  阈值区间

Fig. 5 Evidence-phenomenon rule No.1 for threshold interval  $\tilde{\alpha}_{1,1}$

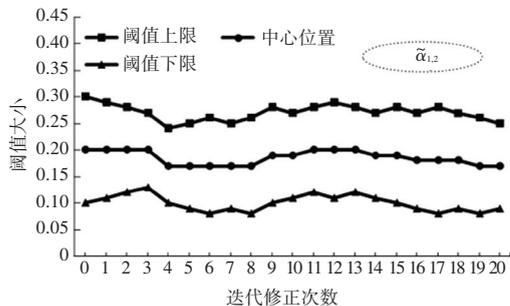


图 6 证据-现象规则 No.1 的  $\tilde{\alpha}_{1,2}$  阈值区间

Fig. 6 Evidence-phenomenon rule No.1 for threshold interval  $\tilde{\alpha}_{1,2}$

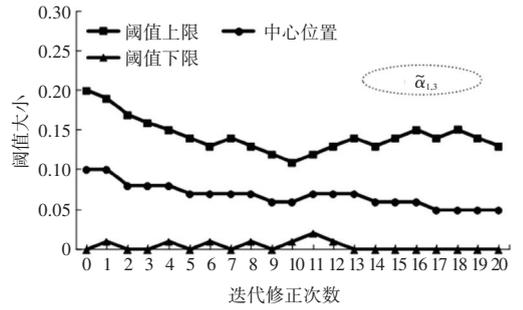


图 7 证据-现象规则 No.1 的  $\tilde{\alpha}_{1,3}$  阈值区间

Fig. 7 Evidence-phenomenon rule No.1 for threshold interval  $\tilde{\alpha}_{1,3}$

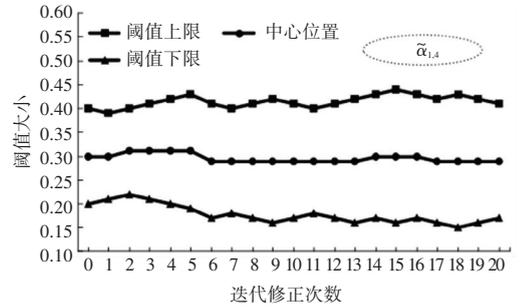


图 8 证据-现象规则 No.1 的  $\tilde{\alpha}_{1,4}$  阈值区间

Fig. 8 Evidence-phenomenon rule No.1 for threshold interval  $\tilde{\alpha}_{1,4}$

从图 5 中可知, 对于“GPS 定位数据异常”证据的加权累计度阈值区间  $\tilde{\alpha}_{1,1}$ , 在第 1 次和第 2 次迭代修正后, 由于若干个实际加权累计度分布点  $\hat{\alpha}_{1,1}$  在  $\tilde{\alpha}_{1,1}$  中散布得较为均匀, 且通过算法得出的可信度未达到初始可信度取值 0.8, 因此区间发生了收缩; 在第 3 次迭代修正后, 阈值上下限和中心位置都呈现相同幅度的增长, 这是因为此时  $\hat{\alpha}_{1,1}$  主要集中于  $\tilde{\alpha}_{1,1}$  的右侧区间, 即分布点右偏, 因此中心位置发生了平移; 在第 7 次迭代修正后, 可以看出阈值下限减小、阈值上限增大, 说明通过算法计算出的可信度已经超过了 0.8, 认为  $\tilde{\alpha}_{1,1}$  收缩得过小, 因此区间发生了扩张。

在经过 20 次迭代后,  $\tilde{\alpha}_{1,1}$  的阈值区间与初始阈值区间相比范围更小, 区间中心位置更高, 表示模型在运行过程中发现初始阈值区间的范围设置得较大, 实际值比通过专家经验给出的估计值更高。图 6~ 图 8 所展示的迭代修正过程与图 5 相类似, 表 8 展示了证据-现象知识库在 20 次迭代后的阈值区间修正结果, 即  $\tilde{\alpha}_{i,j}$ 。

图 9 和图 10 展示了现象-故障规则 No.1 中各条件项对应阈值区间的变化, 表 9 展示了现象-故障知识库在 20 次迭代后的阈值区间修正结果, 即  $\tilde{\alpha}_{i,j}$ 。迭代修正过程的解释同理, 不再赘述。

表8 证据-现象知识库的阈值区间修正结果

Tab. 8 Results of threshold interval modification of evidence-phenomenon knowledge base

i	j					
	1	2	3	4	5	6
1	0.39	0.09	0.00	0.17	0.00	0.00
	~	~	~	~	~	~
2	0.49	0.25	0.13	0.41	0.10	0.10
	0.12	0.16	0.21	0.08	0.00	0.00
3	0.30	0.38	0.43	0.24	0.10	0.10
	0.00	0.00	0.28	0.00	0.18	0.21
4	0.10	0.10	0.48	0.10	0.30	0.37
	0.00	0.00	0.17	0.00	0.28	0.17
	0.10	0.10	0.33	0.10	0.44	0.39

关评价指标给出规则阈值区间修正前后的对比分析。表10展示了针对证据-现象知识库的各阈值区间实验结果,对于每种现象,第一行数据是采用初始阈值区间得出的评价指标,第二行是采用修正后阈值区间得出的评价指标,其中,  $AVG(BR)$  表示规则各条件项区间偏差率的平均值。

表10 证据-现象知识库相关评价指标对比结果

Tab. 10 Comparative results for related evaluation indicators of evidence-phenomenon knowledge base %

现象	PC (%)	RC (%)	AVG(BR)
$Y_1$	69.7	67.3	11.4
	82.5	75.0	
$Y_2$	71.8	72.6	12.8
	88.5	67.6	
$Y_3$	75.6	67.2	7.5
	81.9	69.1	
$Y_4$	82.4	72.5	8.4
	90.1	63.4	

观察表10的第二列数据可以发现,修正后的查准率更高,通过平均区间偏差率  $AVG(BR)$  可知,当偏差率越高时,查准率修正后的增幅越大,这说明专家经验给出的初始参数准确性较低,而对区间进行修正后,通过规则推导出现象更为准确,即更接近专家给出的可信度(表6中的  $\omega$ )。表10的第三列数据表示修正前后的查全率,总体变化幅度不大,对于“车辆不定位”现象( $Y_2$ )和“车辆监控无图像”现象( $Y_4$ ),查全率有所下降,这是因为准确率较高时,规则往往会忽略距离集中分布范围较远的数值点,造成规则泛化能力的下降。

表11展示了现象-故障知识库中各规则阈值区间修正前后的实验对比结果,表中相关数据的解释同理,不再赘述。

表11 现象-故障知识库相关评价指标对比结果

Tab. 11 Comparative results for related evaluation indicators of phenomenon-fault knowledge base %

故障	PC	RC	AVG(BR)
$Z_1$	74.8	71.9	12.5
	83.2	73.5	
$Z_2$	68.0	60.7	14.1
	77.6	64.0	
$Z_3$	76.2	80.3	6.4
	81.1	78.8	

根据表10和表11中修正后的规则阈值区间,分别统计现象和故障的查准率和查全率,模型在当前数

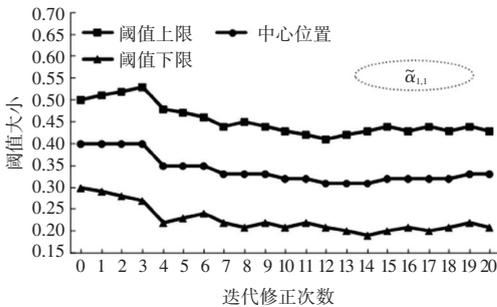


图9 现象-故障规则No.1的 $\tilde{\alpha}_{1,1}$ 阈值区间

Fig. 9 Phenomenon-fault rule No.1 for threshold interval  $\tilde{\alpha}_{1,1}$

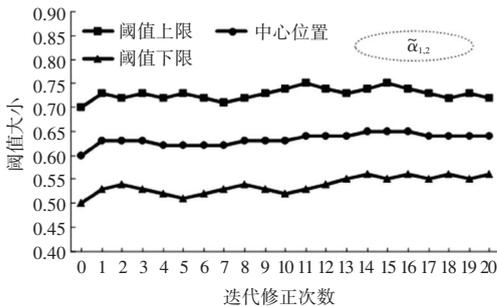


图10 现象-故障规则No.1的 $\tilde{\alpha}_{1,2}$ 阈值区间

Fig. 10 Phenomenon-fault rule No.1 for threshold interval  $\tilde{\alpha}_{1,2}$

表9 现象-故障知识库的阈值区间修正结果

Tab. 9 Results of threshold interval modification of phenomenon-fault knowledge base

i	j			
	1	2	3	4
1	0.21	0.56	0.00	0.00
	~	~	~	~
2	0.43	0.72	0.10	0.10
	0.06	0.17	0.14	0.22
3	0.24	0.35	0.36	0.46
	0.00	0.00	0.23	0.48
	0.10	0.10	0.41	0.66

根据40台车载终端的300日历史数据,结合相

据集上的现象平均查准率和查全率约为85%和69%,故障平均查准率和查全率约为81%和72%,对比修正前的评价指标计算结果(现象平均查准率和查全率约为75%和70%,故障平均查准率和查全率约为73%和72%),修正前后平均查全率相接近,平均查准率显著增长,能够说明模型可靠性的提升。

## 4 结束语

本文通过统计时间片段中的若干种证据实现证据累计度计算;对证据累计度设置关联权重,结合模糊逻辑实现规则匹配与现象推导;根据修正算法动态调整规则的阈值区间。若干种现象推导故障与修正规则的过程同理。模型通过证据、现象和故障之间的累计变化规律,实现车载终端故障检测,且在运行过程中不断修正参数,在现有数据集上具备较好的表现效果。作为初步研究结果,仍有部分问题有待探究,如规则可信度调整问题,规则扩充与筛选问题等。

## 参考文献

- [1] 潘磊. 基于FP-Growth的电力系统故障预测方法[J]. 软件导刊, 2020, 19(10): 152-155.
- [2] YIN Lei, LIU Jianwei, YANG Pu. Interval observer-based fault detection for UAVs formation with actuator faults[C]//2019 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS). Xiamen, China; dblp, 2019: 901-905.
- [3] FANG Dikai, PENG Tao, YANG Chao, et al. Random-Sampling-Based performance evaluation method of fault detection and diagnosis for railway traction system[C]//2019 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS). Xiamen, China; dblp, 2019: 570-574.
- [4] LIU Zhuo, HOUARI A, MACHMOUM M, et al. A second order filter-based fault detection method for five-phase permanent magnet synchronous generators [C]//IECON 2020 The 46<sup>th</sup> Annual Conference of the IEEE Industrial Electronics Society. Singapore; IEEE, 2020: 4827-4832.
- [5] WANG Jian, HU Ya. The vehicle terminal based on GPRS & CDMA communication [C]//2015 IEEE 12<sup>th</sup> Intl Conf on Ubiquitous Intelligence and Computing and 2015 IEEE 12<sup>th</sup> Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15<sup>th</sup> Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom). Beijing; IEEE, 2015: 1657-1660.
- [6] YAHYAOUI A, ABDELLATIF T, YANGUI S, et al. Read-IoT: Reliable event and anomaly detection framework for the internet of things[J]. IEEE Access, 2021, 9: 24168-24186.
- [7] ZENG Wenjie, JIANG Qingpeng, LIU Yinuo, et al. A multi-level fuzzy switching control method based on fuzzy multi-model and its application for PWR core power control [J]. Progress in Nuclear Energy, 2021, 138: 1-12.
- [8] DAWOOD R M S, PILLAI G, AL-GREER M. Fuzzy logic based scheme for directional earth fault detection and classification [C]//2018 53<sup>rd</sup> International Universities Power Engineering Conference (UPEC). Glasgow; IEEE, 2018: 1-6.
- [9] PENG Hong, WANG Jun, MING Jun, et al. Fault diagnosis of power systems using intuitionistic fuzzy spiking neural P systems [J]. IEEE Transactions on Smart Grid, 2018, 9(5): 4777-4784.
- [10] WU Yingjian, WANG Jinglin, CAO Liang. A fault diagnosis method of rotating machinery based on multi-scale fuzzy entropy [C]//2020 11<sup>th</sup> International Conference on Prognostics and System Health Management (PHM-2020 Jinan). Jinan, China; IEEE, 2020: 466-470.
- [11] 李文锋, 游庆和, 廖强, 等. 基于T-S模糊FTA的远程故障诊断方法研究[J]. 控制工程, 2018, 25(09): 1703-1708.
- [12] BERNARDES H, TONELLI-NETO M, MINUSSI C R. Fault classification in power distribution systems using multiresolution analysis and a fuzzy-ARTMAP neural network analysis and a fuzzy-ARTMAP neural network [J]. IEEE Latin America Transactions, 2021, 19(11): 1824-1831.
- [13] FANG Yukun, CHENG Chaoyi, DONG Zhen, et al. A fault diagnosis framework for autonomous vehicles based on hybrid data analysis methods combined with fuzzy PID control [C]//2020 3<sup>rd</sup> International Conference on Unmanned Systems (ICUS). Harbin, China; IEEE, 2020: 281-286.
- [14] SRIVATAVA I, MOHARIR A K, YADAM G. Learning interpretable rules contributing to maximal fuel rate flow consumption in an aircraft using rule based algorithms [C]//2020 IEEE International Conference for Innovation in Technology (INOCON). Bangalore, India; IEEE, 2020: 1-8.
- [15] WANG N, ZHANG F, SHI D. Intelligent EMC management fabric based on knowledge base and machine learning [C]//2018 International Applied Computational Electromagnetics Society Symposium (ACES). Denver, CO, USA; IEEE, 2018: 1-2.
- [16] 刘叙华. 模糊逻辑与模糊推理[M]. 长春: 吉林大学出版社, 1989: 38-42.
- [17] PEKTOR O, WALEK B, MARTINIK I. Extending the Takagi-Sugeno hierarchical expert system for the system for evaluating competencies [C]//2019 20<sup>th</sup> International Carpathian Control Conference (ICCC). Changchun, China; IEEE, 2019: 1-5.