



## 利用置信规则库构建WSN节点故障检测模型

朱海龙, 耿文强, 韩劲松, 张广玲, 冯志超

引用本文:

朱海龙, 耿文强, 韩劲松, 等. 利用置信规则库构建WSN节点故障检测模型[J]. 智能系统学报, 2021, 16(3): 511–517.

ZHU Hailong, GENG Wenqiang, HAN Jinsong, et al. Constructing a WSN node fault detection model using the belief rule base[J]. *CAAI Transactions on Intelligent Systems*, 2021, 16(3): 511–517.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202009006>

## 您可能感兴趣的其他文章

### 移动通信网络的中性集故障诊断方法研究

Research on neutral set fault diagnosis method for mobile communication networks

智能系统学报. 2020, 15(5): 864–869 <https://dx.doi.org/10.11992/tis.201906031>

### 基于改进规则激活率的扩展置信规则库推理方法

Extended belief rule-based reasoning method based on an improved rule activation rate

智能系统学报. 2019, 14(6): 1179–1188 <https://dx.doi.org/10.11992/tis.201906046>

### 网络拓扑特征的不平衡数据分类

Imbalanced data classification of network topology characteristics

智能系统学报. 2019, 14(5): 889–896 <https://dx.doi.org/10.11992/tis.201812014>

### 无人机协助下基于SR-CKF的无线传感器网络节点定位研究

Node localization of wireless sensor networks based on SR-CKF assisted by unmanned aerial vehicles

智能系统学报. 2019, 14(3): 575–581 <https://dx.doi.org/10.11992/tis.201709019>

### 旅游知识图谱特征学习的景点推荐

Tourism knowledge-graph feature learning for attraction recommendations

智能系统学报. 2019, 14(3): 430–437 <https://dx.doi.org/10.11992/tis.201810032>

### 基于GABP-KF的WSN数据漂移盲校准算法

GABP-KF-based blind calibration algorithm of data drift in wireless sensor networks

智能系统学报. 2019, 14(2): 254–262 <https://dx.doi.org/10.11992/tis.201712003>



关注微信公众号, 获取更多资讯信息

DOI: 10.11992/tis.202009006

## 利用置信规则库构建 WSN 节点故障检测模型

朱海龙<sup>1</sup>, 耿文强<sup>1</sup>, 韩劲松<sup>2</sup>, 张广玲<sup>1</sup>, 冯志超<sup>3</sup>

(1. 哈尔滨师范大学 计算机科学与信息工程学院, 黑龙江 哈尔滨 150025; 2. 哈尔滨金融学院 计算机系, 黑龙江 哈尔滨 150030; 3. 火箭军工程大学 导弹工程学院, 陕西 西安 710025)

**摘要:** 在无线传感器网络 (wireless sensor network, WSN) 节点故障检测领域的研究过程中, 故障检测准确率会受节点数据的不确定性和专家知识模糊性的影响。针对这一问题, 本文提出了一种基于置信规则库 (belief rule base, BRB) 的 WSN 节点故障检测方法。首先, 根据 WSN 工作原理及节点工作特性描述 WSN 节点故障检测过程; 然后, 从空间和时间 2 个维度对节点数据提取特征, 建立基于空间和时间相关性的 WSN 节点故障检测模型; 最后, 利用 Intel Lab Data 无线传感器数据集进行案例研究以验证模型的有效性。结果证明, 本文方法能够统筹利用专家知识和节点数据实现 WSN 节点故障检测。

**关键词:** 无线传感器网络; 故障检测; 数据不确定性; 专家知识模糊性; 时间相关性; 空间相关性; 置信规则库; Intel Lab Data 数据集

中图分类号: TP393 文献标志码: A 文章编号: 1673-4785(2021)03-0511-07

中文引用格式: 朱海龙, 耿文强, 韩劲松, 等. 利用置信规则库构建 WSN 节点故障检测模型 [J]. 智能系统学报, 2021, 16(3): 511-517.

英文引用格式: ZHU Hailong, GENG Wenqiang, HAN Jinsong, et al. Constructing a WSN node fault detection model using the belief rule base[J]. CAAI transactions on intelligent systems, 2021, 16(3): 511-517.

## Constructing a WSN node fault detection model using the belief rule base

ZHU Hailong<sup>1</sup>, GENG Wenqiang<sup>1</sup>, HAN Jinsong<sup>2</sup>, ZHANG Guangling<sup>1</sup>, FENG Zhichao<sup>3</sup>

(1. School of Computer Science and Information Engineering, Harbin Normal University, Harbin 150025, China; 2. Department of Computer Science, Harbin Finance University, Harbin 150030, China; 3. Missile Engineering College, Rocket Force University of Engineering, Xi'an 710025, China)

**Abstract:** The WSN node fault detection accuracy is affected by uncertain factors, including the uncertainty of node data and the ambiguity of expert knowledge. This paper proposes a WSN node fault detection method based on the belief rule base. First, the WSN node fault detection process is described according to the working principle of the WSN and the working characteristics of the node. Node data are extracted from two dimensions of space and time, and then the WSN node fault detection model is established based on space and time correlation. We use the Intel lab data wireless sensor data set to conduct a case study to verify the effectiveness of the model. The experimental results indicate that the method proposed in this paper can coordinate the use of expert knowledge and node data to realize the fault detection of WSN nodes.

**Keywords:** wireless sensor network; fault detection; data uncertainty; expert knowledge ambiguity; time correlation; spatial correlation; belief rule base; Intel Lab Data dataset

无线传感器网络 (WSN) 已广泛用于大型工业结构件的安全检测<sup>[1]</sup>、军事领域的实时信息采集<sup>[2]</sup>、生态环境监测<sup>[3]</sup>、辅助农业生产和复杂的机械控制等领域<sup>[4-5]</sup>。在实际应用中, 传感器节点发生故障和通信信道受到干扰等因素会导致传感器

节点采集数据不完整不准确, 同时传感器节点工作环境的复杂性和 WSN 的无中心特性也会增加人工维护和故障排查的难度, 所以对 WSN 节点进行实时准确地故障检测对无线传感器网络的应用和发展具有十分重要的意义。目前对 WSN 节点的故障检测方法主要分为 2 种: 1) 基于数据驱动的 WSN 节点故障检测方法<sup>[6-15]</sup>; 2) 基于专家知识的 WSN 节点故障检测方法<sup>[16-17]</sup>。

收稿日期: 2020-09-07.

基金项目: 国家自然科学基金项目 (61370031, 61773388); 黑龙江省自然科学基金项目 (F2018023).

通信作者: 韩劲松. E-mail: hanjinsong1970@163.com.

方法 1 需要处理大量的传感器数据,且算法准确性依赖于传感器节点发送数据的完整性和准确性。典型的数据驱动方法又分为构建神经网络<sup>[6-8]</sup>及构建数据模型 2 种方式<sup>[9-15]</sup>。方法 2 基于专家知识,算法检测准确率较高,但检测准确率依赖于专家知识的准确性。如文献[16]提出一种基于可信度和邻居协作的 WSN 节点故障检测算法,依赖可信度模型以及邻居节点的诊断回复完成节点故障检测过程。目前大部分 WSN 故障检测方法无法准确地描述不确定、模糊以及未知信息,导致故障检测失去可靠性。为解决该问题,有学者使用证据推理规则描述不确定、模糊以及未知信息<sup>[18]</sup>。杨建波等<sup>[19]</sup>在证据推理基础上进一步提出置信规则库(belief rule base, BRB)模型。相比其他故障检测算法,置信规则库在具备数据样本可训练的优势上集成了专家知识,同时使用半定量信息描述数据不确定性和专家知识模糊性 2 个不确定信息,还具有过程可解释、结果可追溯等优点。因此,本文引入置信规则库开展故障检测算法的研究。同时,为了准确地描述传感器数据的变化趋势和节点间数据的相关程度,在置信规则库基础上加入时间相关性和空间相关性来描述故障检测过程。

## 1 问题描述

### 1.1 基本假设

**假设 1** 故障检测输出的结果包括正常故障、偏移故障、高噪声故障、离群点故障和固定值故障,用  $\hat{Y}(t)$  表示。

**假设 2** 数据处理中心接收到的传感器数据用矩阵  $X_m^n(t)$  表示,该矩阵为第  $n$  个传感器在  $t$  时刻接收到的第  $m$  个属性的数据,如式(1)所示:

$$X_m^n(t) = \begin{bmatrix} x_1^1(t) & x_2^1(t) & \cdots & x_m^1(t) \\ \vdots & & & \vdots \\ x_1^n(t) & x_2^n(t) & \cdots & x_m^n(t) \end{bmatrix} \quad (1)$$

故障检测过程需要的数据特征(模型的前提属性)用矩阵  $A_m^n(t)$  表示,为第  $n$  个传感器在  $t$  时刻获取的第  $m$  个前提属性的值,见式(2)所示:

$$A_m^n(t) = \begin{bmatrix} a_1^1(t) & a_2^1(t) & \cdots & a_m^1(t) \\ \vdots & & & \vdots \\ a_1^n(t) & a_2^n(t) & \cdots & a_m^n(t) \end{bmatrix} \quad (2)$$

### 1.2 WSN 节点故障检测

为检测故障需要依据式(3)提取数据特征:

$$A_m^n(t) = g(X_m^n(t), \sigma) \quad (3)$$

式中:  $g(\cdot)$  为特征提取函数;  $\sigma$  表示转换过程中用到的参数集合。在此基础上,故障检测的过程可用式(4)描述:

$$\hat{Y}(t) = h(A_m^n(t), \lambda) \quad (4)$$

式中:  $h(\cdot)$  表示从前提属性到故障检测结果的转换过程;  $\lambda$  表示转换过程中用到的参数集合。结合式(3)、(4),故障检测过程可描述为

$$\hat{Y}(t) = h(g(X_m^n(t), \sigma), \lambda) \quad (5)$$

## 2 构建节点故障检测模型

### 2.1 故障检测模型建立

由第 1 节可知本文的故障检测包括前提属性提取和传感器故障类型确定 2 个过程,可用图 1 直观表示出来。

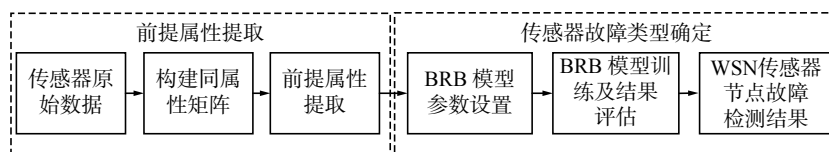


图 1 故障检测模型工作流程

Fig. 1 Workflow of the fault detection model

在模型前提属性提取部分,数据处理中心采集汇聚节点发送的传感器数据后,由故障检测模型进行同属性数据筛选;将被检测传感器节点集群同属性数据构建成数据矩阵,然后以同属性矩阵为目标提取前提属性以构建前提属性矩阵  $A_m^n(t)$ 。在传感器节点故障类型确定过程中,利用时空相关性对当前传感器网络进行数据分析,然后采用专家知识确定置信规则库模型的初始参数,再将前提属性矩阵  $A_m^n(t)$  作为样本集输入 BRB 模型中进行训练,并通过 CMA-ES 算法对模型进行优

化后,最终构建 WSN 传感器节点故障检测模型。

### 2.2 BRB 前提属性提取

#### 2.2.1 时间相关性

采用文献[20]提出的趋势相关性表述相邻节点在某一时间段内数据的趋势变化相似性:

$$X_m^i(t) = [x_m^i(t-k) \ x_m^i(t-k+1) \ \cdots \ x_m^i(t)]$$

式中  $X_m^i(t)$  为节点  $i$  在某个滑动时间窗口  $[t-k, t]$  内采集到的属性  $m$  的  $k+1$  维传感器数据。计算数据方差  $v(i)$  和均值  $\bar{X}_m^i(t)$  后可得节点  $i, j$  数据集合的协方差  $c(i, j)$ :

$$c(i, j) = \sum_{k=1}^{m+1} \left[ x_m^j(t-k+1) - \bar{X}_m^j(t) \right] \times \sum_{k=1}^{m+1} \left[ x_m^j(t-k+1) - \bar{X}_m^j(t) \right] \times m^{-1}$$

进一步可得节点  $i, j$  在时刻  $t$  的趋势相关性系数定义为

$$\chi_{i,j}(t) = c(i, j) / \sqrt{v(i)v(j)} \quad (6)$$

趋势相关性系数  $\chi_{i,j}(t)$  取值范围为  $[-1, 1]$ , 该系数趋近于 1 时表示传感器数据序列  $X_i(t)$  和  $X_j(t)$  正相关性程度越高。

### 2.2.2 空间相关性

本文用空间相关性表示相邻节点在某一时刻的数据相似程度, 空间相关性使用残差计算获得:

$$X_m^i(t) = [x_m^i(t-k) \ x_m^i(t-k-1) \ \cdots \ x_m^i(t)]$$

式中  $X_m^i(t)$  表示节点  $i$  在某个滑动时间窗口  $[t-k, t]$  内获得的关于属性  $m$  的  $k+1$  维的传感器数据集合。用  $\eta_i(t)$  表示节点  $i$  在某个时刻  $t$  的残差值, 即

$$\eta_i(t) = x_m^i(t) - \bar{X}_m(t) \quad (7)$$

式中  $\bar{X}_m(t)$  为当前传感器簇内除节点  $i$  以外所有传感器节点在  $t$  时刻采集到属性  $m$  的平均值。

## 2.3 建立置信规则库模型

### 2.3.1 模型规则建立

置信规则库 (BRB) 的建模依赖于一系列的置信规则, 其中第  $k$  条置信规则可以描述为

$$\beta_n = \left[ \mu \times \prod_{l=1}^L \left( \omega_l \beta_{n,l} + 1 - \omega_l \sum_{i=1}^N \beta_{i,l} \right) - \mu \times \prod_{l=1}^L \left( 1 - \omega_l \sum_{i=1}^N \beta_{i,l} \right) \right] \times \left[ 1 - \mu \times \left[ \prod_{l=1}^L (1 - \omega_l) \right] \right]^{-1}$$

$$\mu = \left[ \left[ \sum_{i=1}^N \prod_{l=1}^L \left( \omega_l \beta_{n,l} + 1 - \omega_l \sum_{i=1}^N \beta_{i,l} \right) \right] - (N-1) \prod_{l=1}^L \left( 1 - \omega_l \sum_{i=1}^N \beta_{i,l} \right) \right]$$

### 4) 效用计算得出结果

$$y = \sum_{n=1}^N \mu(D_n) \beta_n$$

### 2.3.3 模型优化

在优化之前首先需要确定规则权重  $\theta_k$ 、属性权重  $\delta_M$  和置信度  $\beta_{n,k}$  的约束条件, 具体描述如下:

1) 规则权重, 在置信规则库模型构建时, 对于每一条置信规则  $R_k$  所对应的规则权重  $\theta_k$  需要满足的约束条件为  $0 \leq \theta_k \leq 1, k=1, 2, \dots, L$ 。

2) 属性权重, 在置信规则库模型构建时, 需要确定  $M$  个前提属性对应的属性权重  $\delta_M$ , 其对应的约束条件为  $0 \leq \delta_i \leq 1, i=1, 2, \dots, M$ 。

3) 对于第  $k$  条规则, 其对应的第  $N$  个结果  $D_N$  出现的概率可以用置信度  $\beta_{n,k}$  表示, 置信度  $\beta_{n,k}$  的约束条件可描述为

$$0 \leq \beta_{n,k} \leq 1, \quad n=1, 2, \dots, N; k=1, 2, \dots, L$$

$$R_k: \text{if } x_1 \text{ is } A_1, \dots, x_M \text{ is } A_M \\ \text{then } \{(D_1, \beta_{1,k}), (D_2, \beta_{2,k}), \dots, (D_N, \beta_{N,k})\} \\ \text{with rule weight } \theta_k \\ \text{and attribute weight } \delta_1, \delta_2, \dots, \delta_M$$

其中:  $R_k$  表示置信规则库模型的第  $k$  条置信规则;  $x_1, x_2, \dots, x_M$  为一个样本的  $M$  个前提属性;  $A_1, A_2, \dots, A_M$  表示  $M$  个前提属性对应的参考值;  $D_1, D_2, \dots, D_N$  表示置信规则库输出的  $N$  个结果;  $\beta_{N,k}$  表示在第  $k$  条置信规则下第  $N$  个结果对应的置信度;  $\theta_k$  为第  $k$  条置信规则的规则权重;  $\delta_1, \delta_2, \dots, \delta_M$  表示每个前提属性的属性权重。

### 2.3.2 模型推理

在置信规则库的构建过程中需要设定前提属性和与之对应的参考值, 通过前提属性间的一一映射, 初始置信表被构建出来。基于杨剑波等<sup>[19-22]</sup>提出的 ER 解析算法对置信规则进行规则融合, 可得本文置信规则库模型的推理过程:

#### 1) 计算规则匹配度

$$F_i^k = \begin{cases} (R_i^{l+1} - x_i) \times (R_i^{l+1} - R_i^l)^{-1}, & k=1 \text{ 且 } R_i^l \leq x_i \leq R_i^{l+1} \\ 1 - F_i^k, & k=l+1 \\ 0, & k=1, \dots, K; k \neq l; k \neq l+1 \end{cases}$$

#### 2) 计算激活规则的激活权重

$$\omega_k = \theta_k \prod_{i=1}^M (F_i^k)^{\delta_i} \times \left[ \sum_{i=1}^K \theta_i \prod_{i=1}^M (F_i^k)^{\delta_i} \right]^{-1}$$

#### 3) ER 解析算法进行规则融合

同时所有置信规则置信度总和可以表示为

$$\sum_{n=1}^N \beta_{n,k} \leq 1, \quad n=1, 2, \dots, N; k=1, 2, \dots, L$$

其次, 模型预测结果的精度表示为

$$\psi(\hat{Y}_n(t)) = \frac{1}{N} \sum_{n=1}^N (\hat{Y}_n(t) - \hat{\varphi}_n(t))^2 \quad (8)$$

式中:  $N$  为测试样本的数量;  $\hat{Y}_n(t)$  表示第  $n$  个样本的实际预测值;  $\hat{\varphi}_n(t)$  表示第  $n$  个样本的期望预测值。根据文献 [23-25] 中对 CMA-ES 优化算法的描述, 定义模型优化过程如图 2 所示。

## 3 案例研究

在本节中, 使用 Intel Lab Data 无线传感器数据集作为验证数据集, 来检验本文所提故障检测方法的有效性。

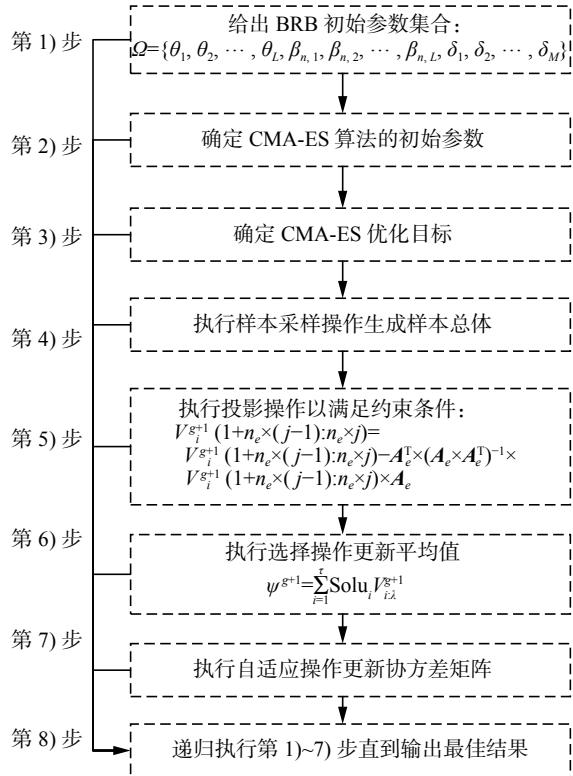


图2 BRB模型优化流程

Fig. 2 BRB model optimization flow

### 3.1 实验定义

根据不同的实验要求生成的实验样本集描述如下:

1) 数据集1: 选取3月1~7日内传感器所有节点的温度数据, 采样完成后以10 min为间隔求解温度数据均值。经过上述处理得到数据集1, 共包含1008个样本数据。

2) 数据集2: 通过对传感器节点进行分簇, 选择传感器1、2、3、4作为实验节点, 节点1为故障节点, 以6个样本点为步距将1008个温度数据分为168组, 每组6个样本点。1~32组为正常样本, 33~66组为偏移故障, 67~100为高噪声故障, 101~134为离群点故障, 135~168为固定值故障。基于故障类型设置相应的故障类型标签0、1、2、3、4, 并生成数据集2。

### 3.2 模型参数设置

为构建基于BRB的WSN节点故障检测模型, 需要事先确定模型的前提属性。通过分析前提属性 $A_1$ 和前提属性 $A_2$ 的数值特性与变化趋势, 可以确定这2个前提属性的参考点。对于前提属性 $A_1$ , 确定其7个参考点, 分别是非常低( $S$ )、较低( $J$ )、低( $L$ )、中等( $M$ )、高( $H$ )、较高( $B$ )、非常高( $T$ )。前提属性 $A_1$ 的参考点可描述为

$$A_1 = \{S, J, L, M, H, B, T\} \quad (9)$$

前提属性2参考点的选取方式与前提属性1

保持一致, 前提属性 $A_2$ 的参考点可描述为

$$A_2 = \{S, J, L, M, H, B, T\} \quad (10)$$

对于BRB模型的输出结果, 确定5个参考点, 分别是正常( $N$ )、偏移故障( $O$ )、高噪声故障( $G$ )、离群点故障( $D$ )、固定值故障( $F$ )。结果 $\hat{Y}(t)$ 的参考点可描述为

$$\hat{Y} = \{N, O, G, D, F\} \quad (11)$$

前提属性1、前提属性2和输出结果参考点及其对应参考值设置如表1、2所示。

表1 前提属性1、2参考点及参考值

Table 1 Referential points and values of the premise attributes 1 and 2

参考点	$S$	$J$	$L$	$M$	$H$	$B$	$T$
属性1	-16	-2.70	-0.38	3.1	5.40	14	18
属性2	-1.10	-0.80	-0.35	0	0.35	0.80	1.10

表2 输出结果 $\hat{Y}(t)$ 参考点及参考值Table 2 Referential points and values of  $\hat{Y}(t)$ 

参考点	$N$	$O$	$G$	$D$	$F$
参考值	0	1	2	3	4

前提属性和输出结果的参考点及参考值设置合理以后, 即可进行置信表的设置, 将前提属性1和前提属性2的所有参考点进行充分组合, 组成置信规则。本文中置信表置信规则数目为2个前提属性参考点数量之积, 置信规则数为49条, 每条规则对应的5个结果的置信度由专家知识进行确定。

### 3.3 实验结果分析

#### 3.3.1 实验结果

为了使模型具有较强的泛化能力, 在实验过程中将训练集设置为测试集的一半, 在本实验中, 将168组残差、趋势相关性以及结果标签组成测试集, 则可确定模型训练所需的样本规模为84组。

为验证BRB模型进行传感器节点故障检测的有效性, 重复了10轮实验, 每轮最大迭代次数为2000次; 使用3个指标进行性能描述以准确地衡量故障检测方法的性能: 均方误差( $\psi$ )、检测准确率( $\tau$ )和错检率( $\rho$ )。经过计算, 得到本文方法的3个性能衡量指标计算结果为0.14、0.95、0.065。本文所提方法在10轮验证实验过程中, 具有95%的故障检测准确率, 表明本文方法可以将95%的样本节点状态检测准确, 故障错检率为0.065表明方法可以将93.5%的样本故障类型正确检测。

#### 3.3.2 对比实验

在本节设置对比实验验证置信规则库(BRB)

在WSN传感器节点故障检测领域中的优越性。设置对比对象为KNN神经网络、随机森林(RF)神经网络、极限学习机(ELM)和BP神经网络。KNN神经网络、RF神经网络、ELM和BP神经网络是典型的数据驱动方法,每轮测试的迭代次数为2000次,每种方法都进行了10轮测试。测试后计算不同方法的各项性能指标(均方误差、故障检测准确率、故障错检率)平均数值。其余性能指标MSE、检测准确率、错检率的均值对比如图3~5所示。

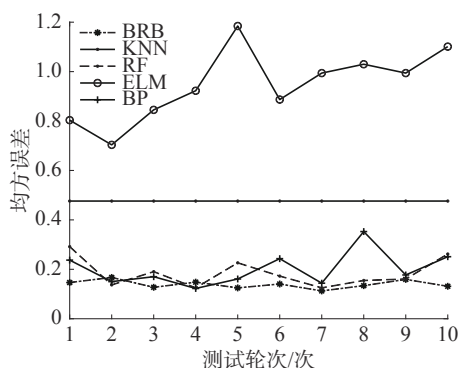


图3 MSE值比较

Fig. 3 Comparison of MSE values

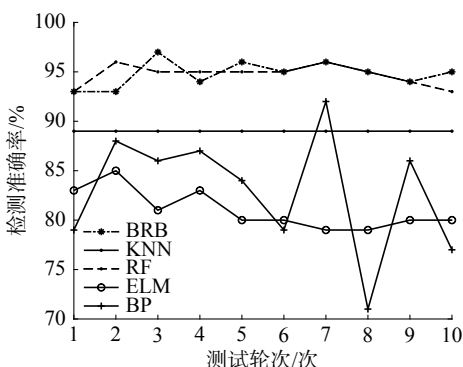


图4 检测准确率比较

Fig. 4 Comparison of detection accuracies

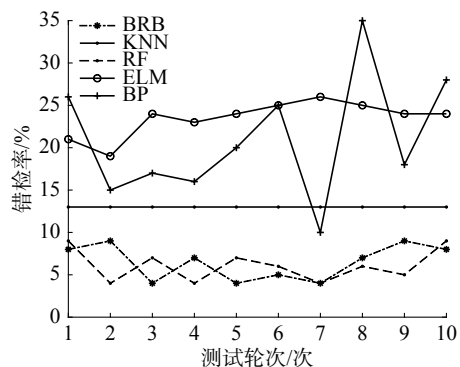


图5 错检率比较

Fig. 5 Comparison of false detection rates

通过3个指标的比较,可以看出本文所提的基于BRB的WSN节点故障检测方法相比其他

4种方法,具有最高的平均检测准确率、最低的平均MSE值和最低的平均错检率,主要指标10轮测试平均值如表3所示。通过表3和图3~5对5种方法的性能进行观察比较,发现本文所提方法相比较KNN、RF、ELM以及BP神经网络具有更高的故障检测精度。

表3 性能指标平均值对比表

Table 3 Comparison of average performance indicators

参数	BRB	KNN	RF	ELM	BP
$\psi$	0.14	0.48	0.19	0.95	0.20
$\tau$	0.95	0.89	0.94	0.81	0.83
$\rho$	0.065	0.13	0.061	0.24	0.20

## 4 结束语

本文提出的基于置信规则库的WSN传感器节点故障检测算法,用残差和趋势相关性描述传感器数据趋势变化和数值相似性,进行故障节点定位和故障类型确定;同时使用残差和趋势相关性并结合专家知识来确定模型的初始参数。实验结果证明,该方法减少了不确定性信息对故障检测准确率的影响,增强了BRB在WSN传感器节点故障检测中的有效性。但BRB在WSN中的应用仅仅处于开始阶段,日后的工作将从以下几方面进行:

- 1) 探索BRB在干扰环境下对WSN传感器节点故障检测的有效性;
- 2) 探索深度学习、大数据技术与BRB的融合应用,并运用到WSN传感器节点故障检测中;
- 3) 探索BRB在复杂网络拓扑WSN中故障检测的应用。

## 参考文献:

- [1] 魏访,郑朝霞. 基于无线传感器网络的工业环境温湿度监测系统[J]. 仪表技术与传感器, 2018(5): 55-57, 82.  
WEI Fang, ZHENG Zhaoxia. Industrial environment temperature and humidity monitoring system based on wireless sensor network[J]. Instrument technique and sensor, 2018(5): 55-57, 82.
- [2] 宋航,李建成,张春华,等. 军事物联网的关键技术[J]. 国防科技, 2015, 36(6): 24-34.  
SONG Hang, LI Jiangcheng, ZHANG Chunhua, et al. Overview of military IoT key technologies[J]. National defense science & technology, 2015, 36(6): 24-34.
- [3] 苗春雷. 无线传感器网络在环境监测中的应用[J]. 环境

- 与发展, 2017, 29(10): 144, 148.
- MIAO Chunlei. Application of wireless sensor network in environmental monitoring[J]. *Environment and development*, 2017, 29(10): 144, 148.
- [4] 杨莺, 杨武德, 吴华瑞, 等. 基于移动 sink 的农田无线传感器网络数据收集策略 [J]. *计算机科学*, 2019, 46(4): 106–111.
- YANG Ying, YANG Wude, WU Ruihua, et al. Mobile sink based data collection strategy for farmland WSN[J]. *Computer science*, 2019, 46(4): 106–111.
- [5] 向模军, 邹承俊. 无线传感器网络在农业应用中的特点和前景 [J]. *中国沼气*, 2018, 36(4): 54–60.
- XIANG Mojun, ZOU Chengjun. Characteristics and prospects of wireless sensor networks in agricultural applications[J]. *China biogas*, 2018, 36(4): 54–60.
- [6] 周奚, 薛善良. 基于改进的粗糙集和神经网络的 WSN 故障诊断 [J]. *计算机科学*, 2016, 43(S2): 21–25.
- ZHOU Xi, XUE Shanliang. WSN fault diagnosis with improved rough set and neural network[J]. *Computer science*, 2016, 43(S2): 21–25.
- [7] 薛善良, 杨佩茹, 周奚. 基于模糊神经网络的 WSN 无线数据收发单元故障诊断 [J]. *计算机科学*, 2018, 45(5): 38–43.
- XUE Shanliang, YANG Peiru, ZHOU Xi. WSN wireless data transceiver unit fault diagnosis with fuzzy neural network[J]. *Computer science*, 2018, 45(5): 38–43.
- [8] 黄旭. MRNN: 一种新的基于改进型递归神经网络的 WSN 动态建模方法: 应用于故障检测 [J]. *计算机工程与科学*, 2015, 37(4): 711–718.
- HUANG Xu. MRNN: A novel wireless sensor network dynamic modeling method for fault detection using modified recurrent neural network[J]. *Computer engineering & science*, 2015, 37(4): 711–718.
- [9] 常琳, 黄志清, 张严心. 基于数据驱动的 WSN 节点故障诊断算法 [J]. *计算机工程*, 2017, 43(9): 105–109.
- CHANG Lin, HUANG Zhiqing, ZHANG Yanxin. Node fault diagnosis algorithm in WSN based on data driven[J]. *Computer engineering*, 2017, 43(9): 105–109.
- [10] LU Siliang, ZHOU Peng, WANG Xiaoxian, et al. Condition monitoring and fault diagnosis of motor bearings using under sampled vibration signals from a wireless sensor network[J]. *Journal of sound and vibration*, 2018, 414: 81–96.
- [11] SUN Qiaoyan, SUN Yumei, LIU Xuejiao, et al. Study on fault diagnosis algorithm in WSN nodes based on RPCA model and SVDD for multi-class classification[J]. *Cluster computing*, 2019, 22(3): 6043–6057.
- [12] JIN Xiaohang, CHOW T W S, SUN Yi, et al. Kuiper test and autoregressive model-based approach for wireless sensor network fault diagnosis[J]. *Wireless networks*, 2015, 21(3): 829–839.
- [13] DARWISH S M, EL-DIRINI M N, ABD EL-MOGHITH I A. An adaptive cellular automata scheme for diagnosis of fault tolerance and connectivity preserving in wireless sensor networks[J]. *Alexandria engineering journal*, 2018, 57(4): 4267–4275.
- [14] 兰涯雯, 李强, 邓淑桃, 等. 基于多属性关联决策的 WSN 故障检测方法 [J]. *计算机工程*, 2019, 45(10): 84–89.
- LAN Yawen, LI Qiang, DENG Shutao, et al. WSN fault detection method based on correlative multi-attribute decision-making[J]. *Computer engineering*, 2019, 45(10): 84–89.
- [15] 周光海, 宁兆龙, 陈志奎, 等. 基于核偏最小二乘法的物联网无线传感网络故障分析与研究 [J]. *通信学报*, 2017, 38(S2): 94–98.
- ZHOU Guanghai, NING Zhaolong, CHEN Zhikui, et al. Fault analysis and research of wireless sensor network based on kernel partial least squares[J]. *Journal on communications*, 2017, 38(S2): 94–98.
- [16] 蔺艳斐, 邵苏杰, 钟成, 等. 基于可信度和邻居协作的传感器故障检测算法 [J]. *通信学报*, 2016, 37(9): 183–190.
- LIN Yanfei, SHAO Sujie, ZHONG Cheng, et al. Sensor fault detection algorithm based on credibility and neighbor-cooperation[J]. *Journal on communications*, 2016, 37(9): 183–190.
- [17] 徐晓斌, 张光卫, 王尚广, 等. 基于群体信任的 WSN 异常数据过滤方法 [J]. *通信学报*, 2014, 35(5): 108–117, 123.
- XU Xiaobin, ZHANG Guangwei, WANG Shangguang, et al. Abnormal data filtering approach based on collective trust for WSN[J]. *Journal on communications*, 2014, 35(5): 108–117, 123.
- [18] YANG Jianbo. Rule and utility based evidential reasoning approach for multiattribute decision analysis under uncertainties[J]. *European journal of operational research*, 2001, 13(1): 31–61.
- [19] YANG Jianbo, LIU Jun, WANG Jin, et al. Belief rule-base inference methodology using the evidential reasoning approach-RIMER[J]. *IEEE transactions on systems, man, and cybernetics-part A: systems and humans*, 2006, 36(2): 266–285.
- [20] 符修文, 杨勇生, 姚海庆. 基于趋势相关性的传感器网络故障检测算法 [J]. *华中科技大学学报(自然科学版)*,

- 2018, 46(10): 98–104.
- FU Xiuwen, YANG Yongsheng, YAO Haiqing. Fault detection algorithm for sensor network based on tendency-similarity[J]. *Journal of Huazhong University of Science and Technology (natural science edition)*, 2018, 46(10): 98–104.
- [21] YANG Jianbo, XU Dongling. Evidential reasoning rule for evidence combination[J]. *Artificial intelligence*, 2013, 205: 1–29.
- [22] XU Dongling, LIU Jun, YANG Jianbo, et al. Inference and learning methodology of belief-rule-based expert system for pipeline leak detection[J]. *Expert systems with applications*, 2007, 32(1): 103–113.
- [23] HU Guanyu, ZHOU Zhijie, ZHANG Bangcheng, et al. A method for predicting the network security situation based on hidden BRB model and revised CMA-ES algorithm[J]. *Applied soft computing*, 2016, 48: 404–418.
- [24] ZHAO Fuqing, DU Songlin, ZHANG Yi, et al. Hybrid biogeography-based optimization with enhanced mutation and CMA-ES for global optimization problem[J]. *Service oriented computing and applications*, 2020, 14(1): 65–73.
- [25] HANSEN N, MÜLLER S D, KOUMOUTSAKOS P. Re-

ducing the time complexity of the derandomized evolution strategy with covariance matrix adaptation (CMA-ES)[J]. *Evolutionary computation*, 2003, 11(1): 1–18.

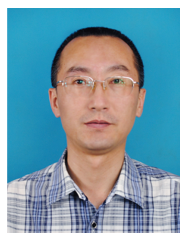
### 作者简介:



朱海龙, 副教授, 主要研究方向为模式识别、数字图像处理。参与国家自然科学基金项目 1 项, 主持黑龙江省自然科学基金 1 项, 黑龙江省教育厅项目 1 项。出版专著 1 部, 发表学术论文 20 余篇。



耿文强, 硕士研究生, 主要研究方向为故障检测、置信规则库理论。



韩劲松, 副教授, 主要研究方向为计算机网络、数字图像处理。主持省级以上项目 3 项。出版专著 2 部, 发表学术论文 10 余篇。