

# 基于模糊神经网络的 WSN 无线数据收发单元故障诊断

薛善良 杨佩茹 周 奚

(南京航空航天大学计算机科学与技术学院 南京 211106)

**摘 要** 在一些无线传感器网络(Wireless Sensor Network, WSN)安全监测系统中,节点长时间传输大量数据,导致无线数据收发单元容易出现功率下降和功率放大器(Power Amplifier, PA)被烧毁的现象,而此类故障的诊断方法一般比较复杂且低效。针对上述问题,在分析 WSN 单元级故障诊断的基础上,利用无线数据收发单元的电流模型,提出了一种基于模糊神经网络的无线数据收发单元故障诊断方法。首先,根据无线数据收发单元中发射消耗的电流与温度和供电电压的关系,建立电流模型;然后,利用聚类算法确定模糊神经网络模型结构,结合混合学习算法优化模糊规则的前件参数和后件参数;最后,提取训练完的模糊神经网络参数,以建立 WSN 节点故障诊断模型。实验结果表明,提出的无线数据收发单元故障诊断方法的计算量小,诊断准确度高;与高斯过程回归模型相比,其计算量降低了 22.4%,诊断准确度提高了 17.5%。

**关键词** 无线传感器网络,故障诊断,电流模型,模糊神经网络

中图分类号 TP277 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.05.006

## WSN Wireless Data Transceiver Unit Fault Diagnosis with Fuzzy Neural Network

XUE Shan-liang YANG Pei-ru ZHOU Xi

(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract** In some wireless sensor network(WSN) security monitoring systems, the nodes transfer large amounts of data in a long time, which causes the phenomenon of power decreasing and power amplifier(PA) being burned in the wireless data transceiver unit, but this kind of fault diagnosis method is generally complex and inefficient. In order to solve these problems, based on the analysis of WSN cell-level fault diagnosis, this paper proposed a fault diagnosis method based on fuzzy neural network by using the current model of wireless data transceiver unit. Firstly, according to the relationship between the emission current, the temperature and the supply voltage, the current model is established. Then, the fuzzy neural network model structure is determined by the clustering algorithm, and the hybrid learning algorithm is used to optimize the front and rear parameters of fuzzy rules. Finally, the fuzzy neural network parameters are extracted to establish the WSN node fault diagnosis model. The experimental results show that the presented fault diagnosis method of wireless data transceiver unit possesses low computational complexity and high diagnostic accuracy. Compared with Gaussian process regression model, the computational complexity of this method is reduced by 22.4%, and the diagnostic accuracy is increased by 17.5%.

**Keywords** Wireless sensor network, Fault diagnosis, Current model, Fuzzy neural network

## 1 引言

无线传感器网络是当今国际上备受关注的多学科高度交叉、知识高度集成的前沿热点研究领域<sup>[1]</sup>,其通过与其他技术集成,将逻辑上的信息世界与客观上的物理世界融合在一起,从而改变人类与自然界的交互模式<sup>[2-5]</sup>。相比于传统传感器网络受空间和条件的限制、制作成本高昂、设计精度要求高、部署费时且低效等缺点,WSN 以不受空间限制、成本低、自组网、部署快速便捷等特点在很多应用方面更具优势。例如,在

工业安全领域,将 WSN 部署在危险的化学化工场所,通过部署的监测节点实现可燃气体、烟雾颗粒、火焰、有毒气体、温/湿度等参数的在线检测,并将上述参数、报警信息、现场实时图片上传到终端设备,从而实现对监测场所的快速预警并通知相关人员对事故采取有效的处理措施。为了提高无线安全监测系统的可靠性和稳定性,需要对系统自身的故障进行检测和诊断。

目前已有许多算法应用于 WSN 的故障诊断,常见的包括人工神经网络和小波变换等<sup>[6-7]</sup>,但是这些故障诊断方法主

到稿日期:2017-03-22 返修日期:2017-05-04

薛善良(1972—),男,博士,副教授,主要研究方向为无线传感器网络、计算机应用技术和先进制造技术,E-mail:xuesl@nuaa.edu.cn(通信作者);杨佩茹(1993—),女,硕士生,主要研究方向为无线传感器网络、计算机应用技术,E-mail:330474330@qq.com;周 奚(1991—),男,硕士生,主要研究方向为无线传感器网络、智能故障诊断,E-mail:zhouxi\_email@163.com。

要依赖于从传感器获取信号,进而分析 WSN 系统,而在节点的单元级的应用并不多。在上述应用于化学化工场所的安全监测系统中,由于节点须经常传输数据量较大的现场图片,负载较大,因此当长时间运行时会出现无线数据收发单元功率下降和功率放大器被烧毁的现象,且此类故障的检测方法复杂且耗时。针对现有诊断方法的缺点,在分析 WSN 单元级故障诊断的基础上,根据无线数据收发单元的电流模型,提出一种基于模糊神经网络的无线数据收发单元故障诊断方法,建立了故障诊断模型。其应用混合学习算法建立和调整模糊神经网络的结构和参数,提取经过离线训练的模型参数,对测试样本进行诊断。结果表明,该方法对故障诊断的正确率较高,诊断速度较快且效率较高。

## 2 WSN 节点的单元级故障诊断策略

WSN 节点的故障诊断过程包括:采集数据、故障判断、故障定位和原因诊断。具体诊断步骤如下:

- 1) 监测各个单元的状态参数;
- 2) 监测到异常参数后,将其保存到故障向量中;
- 3) 将单元监测参数矩阵与故障定位矩阵进行运算,得到故障的位置;
- 4) 查找故障诊断表,确定故障原因。

故障诊断向量可以用  $F=(M,P,T,L,R)$  表示。其中,  $M$  表示 WSN 节点上的子单元;  $P$  表示 WSN 各个单元的监测参数;  $T$  表示 WSN 各个单元的监测参数的状态,分为正常状态和异常状态;  $L$  表示故障定位结果,故障定位结果可以通过单元监测参数矩阵与故障定位矩阵运算得到;  $R$  表示故障诊断结果,表明故障对应的可能原因。

依据相关性的不同,  $P$  中的参数可以分为直接相关参数和非直接相关参数。相关性是指其可以根据电路的串/并联传递关系而得到,即处于同一电路回路中的各个单元的监测参数互相影响,一个单元参数的变化无法确定是由自身出现的故障而引起的,还是由于同一回路中其他单元出现故障而联动影响的,因此不能仅仅根据单元的监测参数发生了变化就确定其发生故障,应该根据串/并联关系、电流的方向等相关关系来定位故障的位置。由于 WSN 节点内部单元众多,单元内与单元间因存在串/并联回路的影响而无法简单定位故障位置并确定原因,因此可以引入故障定位矩阵,依据监测参数来定位故障位置并诊断故障原因。

假设故障定位矩阵为  $Q=[X_1, X_2, \dots, X_q]$ ,  $X_i$  表示由电流的流向和单元在 WSN 节点中的串/并联的传递关系而得到的故障定位向量,则故障定位结果为:

$$L_c = P_c \times Q$$

其中,  $P_c$  为  $P$  的子集,  $L_c$  为  $L$  的子集,是故障向量中具有直接相关性的部分。

## 3 模糊神经网络混合学习算法

### 3.1 模糊神经网络的基本原理

本小节详细阐述模糊神经网络<sup>[8]</sup>的基本原理及结构。模糊神经网络的推理规则采用“if-then”,其一般形式是:

规则  $R_k$ : if  $x_1$  is  $A_1^k$ ,  $x_2$  is  $A_2^k$ , ...,  $x_n$  is  $A_n^k$  then  $f_k = p_0^k + p_1^k x_1 + \dots + p_n^k x_n$

其中,  $A_j^k$  是模糊系统的模糊集,  $p_j^k$  是模糊系统的参数;  $f_k$  是根据规则  $R_k$  得到的输出。

本文采用 TSK 模糊神经网络<sup>[9]</sup>。图 1 给出了由  $n$  个输入、1 个输出和  $m$  条模糊规则组成的 TSK 模糊神经网络结构。




图 1 TSK 模糊神经网络结构图

Fig. 1 Structure of TSK fuzzy neural network

图 1 中的模糊神经网络共分为 5 层,详细介绍如下。

第一层为输入层:  $x_i, i=1, 2, \dots, n$ 。其中,  $x_i$  是网络的第  $i$  个输入,此层共有  $n$  个节点。

第二层为模糊化层,用于计算隶属度。常见的隶属度函数包括三角形隶属度函数、梯形隶属度函数、S 形函数、钟形隶属度函数、高斯型隶属度函数等。本文考虑到高斯型隶属度函数在处理非二值输入以及模糊集输入空间映射方面的优势,采用高斯型隶属函:

$$\mu A_j^k(x_j) = \exp\left[-\frac{(x_j - a_j^k)^2}{(\sigma_j^k)^2}\right] \quad (1)$$

其中,  $j=1, 2, \dots, n$ , 表示隶属函数所在的层;  $k=1, 2, \dots, m$ , 表示层中的节点数;  $a_j^k$  是高斯隶属函数的中心;  $\sigma_j^k$  是隶属函数的宽度,  $a_j^k$  和  $\sigma_j^k$  都称为前提参数。

第三层为模糊推理层,采用乘法规则进行计算,其输出表示该条规则的激活强度:

$$\mu_k = \prod \mu A_j^k(x_j) \quad (2)$$

其中,  $\mu_k$  代表第  $k$  条规则的激活强度。

第四层为归一化层,对激活强度进行归一化处理:

$$\bar{\mu}_k = \frac{\mu_k}{\sum \mu_k} \quad (3)$$

第五层为反模糊化层,计算每条规则的输出,并将所有规则求和,计算所有信号的总输出:

$$y = \sum \bar{\mu}_k f_k \quad (4)$$

在上述模糊神经网络中,可以调节的参数有 3 类,第一类是规则中的结论参数  $f_k$ ,代表规则参数;第二、三类分别是高斯型隶属函数的中心和宽度,它们代表隶属函数的参数。

### 3.2 模糊神经网络的学习方式

学习算法基于混合算法的思想,分为 3 个阶段:1)应用聚类算法提取模糊规则;2)应用梯度下降法调节规则的前件参数;3)应用最小二乘法调节规则的后件参数。

1)基于聚类算法的规则提取。应用文献<sup>[10]</sup>中的模糊 C 均值(简称 FCM)算法聚类训练样本集。FCM 是一种基于目标函数的模糊聚类算法,是基于目标函数的模糊聚类算法理

论中最完善、应用最广泛的一种算法,可以获得基于划分聚类分析的全局最优结构。聚类结束后,类的数目初始化隶属函数的中心个数即模糊规则数;类的中心初始化模糊隶属函数的中心参数;所有类中心之间距离的最小值初始化模糊隶属函数的宽度参数;依据部分最小二乘法可以简便地求得未知的数据,并可使这些求得的数据与实际数据之间的误差的平方和最小;应用最小二乘法初始化连接权值即规则的后件参数。学习算法应用无监督学习的 FCM 算法提取规则;为了提高模型的精度和质量,需要进一步优化模型的参数。

2) 基于梯度下降算法的前件参数优化。模糊规则的前件参数包括隶属函数的中心和宽度。采用梯度下降算法进行参数优化,设定目标函数为:

$$E = \frac{1}{2} \sum_{q=1}^N (y_{out}^q - y^q)^2 \quad (5)$$

其中,  $q=1, 2, \dots, N$ ,  $N$  为样本数。

3.1 节中模糊神经网络的输出还可以表示为:

$$y_{out} = z_1 / z_2 = \frac{\sum_{k=1}^m \mu_k f_k}{\sum_{k=1}^m \mu_k} \quad (6)$$

其中:

$$z_1 = \sum_{k=1}^m \mu_k f_k \quad (7)$$

$$z_2 = \sum_{k=1}^m \mu_k \quad (8)$$

其中,  $m$  为规则数,  $\mu_k$  为第  $k$  条规则的激活强度。

采用链规则求导,结合式(2)、式(6)~式(8)可以导出前件参数中模糊隶属函数的中心参数的学习公式:

$$a_j^k(i+1) = a_j^k(i) - \eta \frac{\partial E}{\partial a_j^k} \quad (9)$$

其中:

$$\begin{aligned} \frac{\partial E}{\partial a_j^k} &= \sum_{q=1}^N \left( \frac{\partial E}{\partial y_{out}^q} \frac{\partial y_{out}^q}{\partial \mu_k^q} \frac{\partial \mu_k^q}{\partial \mu A_j^k} \frac{\partial \mu A_j^k}{\partial a_j^k} \right) \\ &= \sum_{q=1}^N (y_{out}^q - y^q) (f_k - y_{out}^q) \frac{\mu_k^q (x_j^q - a_j^k)}{z_2^q (\sigma_j^k)^2} \end{aligned} \quad (10)$$

其中,  $\eta$  为学习率,取值区间为(0, 1)。

同理,按照链规则求导可得前件参数中模糊隶属函数的宽度参数的学习公式:

$$\sigma_j^k(i+1) = \sigma_j^k(i) - \eta \frac{\partial E}{\partial \sigma_j^k} \quad (11)$$

其中:

$$\begin{aligned} \frac{\partial E}{\partial \sigma_j^k} &= \sum_{q=1}^N \left( \frac{\partial E}{\partial y_{out}^q} \frac{\partial y_{out}^q}{\partial \mu_k^q} \frac{\partial \mu_k^q}{\partial \mu A_j^k} \frac{\partial \mu A_j^k}{\partial \sigma_j^k} \right) \\ &= \sum_{q=1}^N (y_{out}^q - y^q) (f_k - y_{out}^q) \frac{\mu_k^q (x_j^q - a_j^k)^2}{z_2^q (\sigma_j^k)^3} \end{aligned} \quad (12)$$

3) 基于部分最小二乘法的后件参数学习。将式(7)和式(8)代入式(6),得到模糊神经网络的输出:

$$y_{out} = \frac{\sum_{k=1}^m \mu_k f_k}{\sum_{k=1}^m \mu_k} \quad (13)$$

将  $f_k$  代入,可以得到:

$$y_{out} = \sum_{k=1}^m \overline{\mu_k} (p_0^k + p_1^k x_1 + \dots + p_n^k x_n) \quad (14)$$

其中,  $\overline{\mu_k}$  是对激活强度  $\mu_k$  进行归一化操作的结果。

很显然,式(14)是一个多元线性模型,待学习的参数有  $(n+1)m$  个。将式(14)写成矩阵的形式:

$$y_{out} = W \times P \quad (15)$$

其中:

$$W = \left[ \begin{array}{c} [\overline{\mu_1}, \overline{\mu_1} x_1, \dots, \overline{\mu_1} x_n], [\overline{\mu_2}, \overline{\mu_2} x_1, \dots, \overline{\mu_2} x_n], \dots, [\overline{\mu_m}, \\ \overline{\mu_m} x_1, \dots, \overline{\mu_m} x_n] \end{array} \right] \quad (16)$$

$$P = \left[ \begin{array}{c} [p_0^1, p_1^1, \dots, p_n^1], [p_0^2, p_1^2, \dots, p_n^2], \dots, [p_0^m, p_1^m, \dots, \\ p_n^m] \end{array} \right] \quad (17)$$

变量  $W$  由输入变量  $X$  扩展而来,其维数是  $(n+1)m$ ,大约是  $X$  的  $m$  倍,但样本数量不变。相对而言,变量  $W$  的维数与输入样本个数的比值显然变大,当每个输入所使用的模糊划分变大或者输入变量个数变多时,将会出现规则数爆增的现象,进而可能会出现变量  $W$  的维数大于样本个数的情况。本文利用部分最小二乘法<sup>[11]</sup>可以较精确地求出变量  $P$ ,以消除这种异常情况。

#### 4 无线数据收发单元的故障诊断方法

在无线监测系统中,节点经常担负传输大量数据的任务,负载较重,长期使用无线数据收发单元会导致该单元的 PA 失效、老化等故障,进而造成通信失效的问题。对这类故障的诊断需要依赖专业设备和专业人员,诊断成本较高。鉴于此,本文给出了一种基于模糊神经网络的无线数据收发单元故障诊断方法,通过建立模糊神经网络电流模型来诊断故障。

##### 4.1 无线数据收发单元的电流模型

Si4463-APC320 型无线数据收发单元的功率放大器易受温度的影响,其发射消耗的电流随温度的变化而变化。当供电电压为 3.2V 时,其变化关系如图 2 所示。




图 2 发射消耗的电流与温度的变化关系

Fig. 2 Relationship between emission current consumption and temperature

WSN 节点通常采用电池供电,而电池具有电量计量的特征,电池在放电时,电池的电压随电量的消耗会逐渐降低,并且有一定的斜率,进而引起发射消耗电流的下降。当温度恒定为 26.5 °C 时,其变化关系如图 3 所示。




图 3 发射消耗的电流与电压的变化关系

Fig. 3 Relationship between emission current consumption and voltage

由图 2 可知,发射消耗的电流随温度的升高而增大;由图 3 可知,发射消耗的电流随供电电压的降低而减小,即温度

和电压的变化会引起发射消耗的电流的变化。依据发射消耗的电流与温度和电压的变化关系建立电流模型,通过对电流模型的数据进行学习训练,诊断出无线数据收发单元的故障。

#### 4.2 模糊神经网络故障诊断模型的建立

为采集不同温度和不同电压对应的发射消耗的电流参数,选用 Si4463-APC320 型无线数据收发单元和 BJYSL-HS-100 型恒温实验箱来搭建实验平台。设置 Si4463 无线数据收发单元的工作参数如表 1 所列。

表 1 Si4463 无线数据收发单元的参数设置

Table 1 Parameters of Si4463 wireless data transceiver unit

单元名称	无线速率	串口速率	通信信道	发射功率	无线频率
Si4463	20 kps	9600 bps	0	+20 dBm	440 MHz

在温度变化范围为 15.9~64.5℃,电压变化范围为 2.2~3.4 V 时,采集不同温度和不同电压下的数据共 100 组,其中 75 组用于模糊神经网络的训练,另外 25 组用于测试。1 组数据包含 2 个输入量和 1 个输出量,输入量分别是供电电压和温度,输出量为发射消耗的电流。

模糊神经网络采用聚类算法提取规则,学习速率  $\eta$  选为 0.005,建立了具有两个输入  $V$  和  $T$ 、一个输出  $I$  以及 13 条模糊规则的 5 层模糊神经网络结构。

相应的模糊规则如下:

(1) If  $x_1$  is  $A_1^1, x_2$  is  $A_2^1$  then  $f_1 = a_0^1 + a_1^1 x_1 + a_2^1 x_2$

(2) If  $x_1$  is  $A_1^2, x_2$  is  $A_2^2$  then  $f_2 = a_0^2 + a_1^2 x_1 + a_2^2 x_2$

(3) If  $x_1$  is  $A_1^3, x_2$  is  $A_2^3$  then  $f_3 = a_0^3 + a_1^3 x_1 + a_2^3 x_2$

...

(13) If  $x_1$  is  $A_1^{13}, x_2$  is  $A_2^{13}$  then  $f_{13} = a_0^{13} + a_1^{13} x_1 + a_2^{13} x_2$

建立模糊推理系统后,应用梯度下降法对非线性关系的规则前件参数进行训练,应用部分最小二乘法对线性关系的规则后件参数进行训练。

### 5 仿真实验及结果分析

仿真实验分为两个部分:1)对比模糊神经网络模型与 BP 神经网络、高斯过程回归模型的效果;2)将模糊神经网络应用于无线数据收发单元的故障诊断实验。

#### 5.1 网络模型效果的对比

为了评估模型的性能,以反向传播(Back Propagation, BP)神经网络和文献[12]中的高斯过程回归(Gaussian Process Regression, GPR)模型作为对比对象。BP 神经网络通过调节扩展常数 spread 和隐含层节点数来获得最佳的网络结构参数;输入神经元个数为 2,隐含层节点数为 8,输出神经元数为 1,构成 2-8-1 的网络结构。两个输入分别为  $V$  和  $T$ ,一个输出为  $I$ 。输入层到隐含层的激活函数为“tansig”,隐含层到输出层的激活函数为“purelin”,训练函数为“trainlm”,训练精度为  $1e-10$ ,最大训练次数为 10000。对高斯过程回归模型进行建模时,先将训练数据进行输入输出规范化,使得数据服从均值为 0、方差为 1 的正态分布,本文选择的均值函数为零均值函数,选取的协方差函数为平方指数协方差函数,对训练样本的对数似然函数采用共轭梯度法获得最优超参数,建立高斯过程模型,将验证数据规范化并输入建立好的高

斯过程模型,再对输出反规范化后便得到验证结果。

经过 Matlab 仿真可得:BP 神经网络经过 798 次迭代,用时 24.123 s 达到精度要求;高斯过程回归模型的训练用时是 0.4889 s;模糊神经网络的前期 FCM 的运算时间为 0.056 s,经过 89 次迭代,用时 0.299 s 达到精度要求,合计用时 0.355 s。BP 神经网络、高斯过程回归和模糊神经网络的模型效果对比曲线如图 4 所示。




图 4 3 种模型的验证数据对比曲线

Fig. 4 Validation data comparison curve of three models

本文以均方差(MSE)、平均绝对误差(MAE)和最大相对误差(MRE)为指标来评价 3 种模型的验证效果。BP 神经网络、高斯过程回归(GPR)和模糊神经网络模型(FNN)的性能对比结果如表 2 所列。由表 2 可知,模糊神经网络的相应误差参数均低于 BP 神经网络和高斯过程回归,而且其耗时更短。TSK 结构是一个集成的模糊模型,通过神经网络训练来实现并优化模糊推理系统,它将输入映射到输入隶属度函数,再映射到输出隶属度函数,最后得到输出。利用混合学习算法修正 if-then 规则和隶属度函数来描述复杂系统的输入和输出的关系,即使没有专家经验,依然能直观地建立合理的隶属度函数;然后通过神经网络的训练产生一些 if-then 规则来逼近得到精度更高的数据集。

表 2 模糊神经网络、GPR 及 BP 神经网络模型的性能对比

Table 2 Performance comparison of fuzzy neural network, GPR and BP neural network

模型类型	模型耗时/s	训练 MSE	验证 MSE	验证 MAE	验证 MRE
BP	24.1230	0.1590	0.3469	0.3987	0.0298
GPR	0.4899	0.0538	0.1879	0.3422	0.0191
FNN	0.3550	0.0161	0.1449	0.2889	0.0172

本节实验显示了基于混合学习算法的模糊神经网络(Fuzzy Neuron Network, FNN)模型在学习速度、误差精度等方面的优越性。因此相较于高斯过程回归模型,采用模糊神经网络模型进行故障诊断的计算量降低了 22.4%,诊断准确度提高了 17.5%。

#### 5.2 基于模糊神经网络的无线数据收发单元的故障诊断

本节实验首先对 4.2 节测得的数据中的训练样本进行离线训练,获得训练后的模糊神经网络参数;接着将其应用于无线数据收发单元的故障诊断测试分析。

##### (1) 模型参数计算

对训练样本进行训练,从而获得训练完毕后的模糊神经网络参数,其网络模型参数如表 3 所列,其中  $c_1^i, \sigma_1^i, c_2^i, \sigma_2^i$  是模糊规则的非线性前提参数;  $a_0^i, a_1^i, a_2^i$  是模糊规则的线性结论参数。

表3 模糊神经网络模型的参数  
Table 3 Parameters of fuzzy neural network model

$n$	$c_1^n$	$\sigma_1^n$	$c_2^n$	$\sigma_2^n$	$a_0^n$	$a_1^n$	$a_2^n$
1	0.889	0.889	-0.297	-0.297	0.284	0.955	-0.308
2	-0.472	-0.472	-1.544	-1.544	3.345	2.534	4.004
3	-0.976	-0.976	-0.941	-0.941	0.006	0.690	-0.279
4	-1.009	-1.009	0.894	0.894	0.064	0.182	0.964
5	0.172	0.172	-0.834	-0.834	3.331	0.0869	-1.342
6	-1.521	-1.521	-1.543	-1.543	3.152	0.645	4.400
7	-1.516	-1.516	0.552	0.552	-0.236	0.501	-0.692
8	-0.332	-0.332	1.668	1.668	-0.514	0.814	-0.295
9	0.251	0.251	1.064	1.064	-1.399	1.389	-0.188
10	1.451	1.451	0.811	0.811	3.626	-0.071	-4.311
11	1.412	1.412	1.166	1.166	0.016	-0.866	3.739
12	-0.363	-0.363	0.359	0.359	0.724	-0.069	0.344
13	1.391	1.391	-1.341	-1.341	0.877	0.791	-1.184

归一化无线数据收发单元的输入数据后,基于表3的参数,利用式(1)~式(4)进行计算,再反归一化数据得到无线数据收发单元的发射消耗电流的模糊神经网络计算值。

#### (2)故障诊断方法的测试结果分析

本文通过将 Si4463 无线数据收发单元的输出功率降低一级的方式来模拟无线数据收发单元的发射功率下降故障。故障诊断的阈值为3.0mA,即当实际发射消耗的电流值与模型的计算值的差值大于3.0mA时,认为出现故障。设定测试环境的温度为26.5℃,电压变化范围为2.2~3.4V。每次测试都将单元的实际发射消耗的电流值和模糊神经网络的电流计算值输出。共进行25次测试,其中8次通过降低一级输出功率来模拟发射功率下降故障。无线数据收发单元的故障诊断结果如图5所示。




图5 基于模糊神经网络的无线数据收发单元故障诊断

Fig.5 Wireless data transceiver unit fault diagnosis with fuzzy neural network

由图5可知,在数据序号为3,6,7,8,13,17,20和25的点上,电流差值的绝对值大于3.0mA,因此它们被诊断为故障。之前人工设置的故障序号为3,6,7,8,13,17,20,25,实际故障序列与诊断模型的输出故障序列一致,说明在阈值为3.0mA的情况下故障全部被检出,没有出现错诊和漏诊情况。

从结构来看,本文的模糊神经网络结构与传统的神经网络有很大的不同,除了拓扑结构不同之外,其最大的不同在于TSK对输入和输出的处理具有一定的物理意义。其对输入的模糊化刻画了一个物理现象在多大程度上属于一个推理前提,对于故障诊断系统而言就表现为测得的物理量对征兆域的隶属度。而网络的输出则是使用重心法综合了各条诊断规则的适用度,即根据当前所输入的诊断向量能否判断是某种故障的一种度量。它的输入输出映射是各个诊断参数的变化区间与故障程度区间的映射。而对于传统的神经网络和其他的一些结构,其输入输出之间的映射是某一个故障特征向量与某一故障是否发生之间的映射,且它的各层并没有实际的

物理意义,只是通过样本对的训练形成了数值上的关系,这就决定了本文的网络结构比传统的神经网络和其他的一些网络结构具有更好的泛化能力,其诊断结果也具有更高的可信度。

对于无线数据收发单元中的常规故障,如短路、断路、电流过大、电流过小等,由于电流差的绝对值很大,因此其故障特征明显,本方法更容易对其进行诊断。本节通过电流差的绝对值很小的功率下降故障来验证模型对无线数据收发单元的故障诊断能力,通过实验说明了基于模糊神经网络的故障诊断方法可以有效地诊断无线数据收发单元的故障。

**结束语** 本文首先研究了WSN节点单元级的故障诊断策略,给出故障位置与故障原因的确定方法。针对WSN节点故障诊断最难的无线数据收发单元部分,给出了一种基于模糊神经网络的无线数据收发单元故障诊断方法。首先使用聚类算法确定模糊神经网络的结构,然后使用梯度下降法和部分最小二乘法相结合的混合学习算法来优化模糊规则的前件参数和后件参数,提取训练已经达到精度要求的模型参数并将其运行于节点中。实验证明,该诊断模型的收敛速度快,训练时间短,故障诊断正确率高,可以有效应用于WSN的无线数据收发单元的故障诊断中,以提高WSN应用的可靠性与实用性。

#### 参考文献

- [1] YICK J, MUKHERJEE B, GHOSAL D. Wireless sensor network survey[J]. *Computer Networks*, 2008, 52(12): 2292-2330.
- [2] REN F Y, HUANG H N, LIN C. Wireless Sensor Networks [J]. *Journal of Software*, 2003, 14(7): 1282-1291. (in Chinese)  
任丰原, 黄海宁, 林闯. 无线传感器网络[J]. *软件学报*, 2003, 14(7): 1282-1291.
- [3] ASADA G, DONG M, LIN T S, et al. Wireless integrated network sensors (WINS) for tactical information systems[C] // *Proceedings of the 1998 European Solid State Circuits Conference*. New York: ACM Press, 1998.
- [4] WU W P. Research on the application of wireless sensor network and Internet of things[J]. *Journal of Jilin Teachers Institute of Engineering and Technology*, 2016, 32(4): 86-88. (in Chinese)  
吴文平. 无线传感器网络与物联网的应用研究[J]. *吉林工程技术师范学院学报*, 2016, 32(4): 86-88.
- [5] AGRAWAL D P. *Applications of Sensor Networks*[M] // *Embedded Sensor Systems*. Singapore: Springer, 2017: 406-426.
- [6] LIN L, XU D, WANG H. Fault diagnosis of WSNs node based on wavelet neural network[J]. *Compel International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 2010, 29(2): 563-570.
- [7] ZHAO J S, LI Y, QIU T. A sensor fault diagnosis method based on wavelet transform and neural network[J]. *Journal of Tsinghua University: Science and Technology*, 2013(2): 205-209. (in Chinese)  
赵劲松, 李元, 邱彤. 一种基于小波变换与神经网络的传感器故障诊断方法[J]. *清华大学学报(自然科学版)*, 2013(2): 205-209.
- [8] ZHAN H W. *Research on Ship Diesel Engine Fault Diagnosis System Based on Fuzzy Neural Network*[D]. Wuhan: Wuhan University of Technology, 2009. (in Chinese)

- 占惠文. 基于模糊神经网络的船舶柴油机故障诊断系统研究[D]. 武汉:武汉理工大学,2009.
- [9] CPALKA K. CaseStudy: Interpretability of Fuzzy Systems Applied to Nonlinear Modelling and Control[M]// Design of Interpretable Fuzzy Systems. Berlin: Springer International Publishing,2017:131-162.
- [10] KOSKO B. Fuzzy engineering[M]. London:Prentice-Hall, Inc., 1996.
- [11] ZHAO W,FAN F,WANG W. Non-linear partialleast squares response surface method for structural reliability analysis[J]. Reliability Engineering & System Safety,2017,161:69-77.
- [12] LI Z G. Network Traffic Prediction Model Based on Gaussian Process Regression[J]. Journal of Computer Applications,2014,34(5):1251-1254. (in Chinese)  
李振刚. 基于高斯过程回归的网络流量预测模型[J]. 计算机应用,2014,34(5):1251-1254.
- (上接第 30 页)
- [31] PANDURANGAN G,ROBINSON P,SCQUIZZATO M. Fast Distributed Algorithms for Connectivity and MST in Large Graphs[C] // 28th ACM Symposium on Parallelism in Algorithms and Architectures. 2016.
- [32] SAHA T,RANGWALA H,DOMENICONI C. Sparsification and Sampling of Networks for Collective Classification[C]// International Conference on Social Computing, Behavioral-Cultural Modeling and Prediction. 2013:293-302.
- [33] SATULURI V,PARTHASARATHY S,RUAN Y. Local graph sparsification for scalable clustering[C]// ACM SIGMOD International Conference on Management of Data (SIGMOD 2011). 2011:721-732.
- [34] KORHONEN,JANNE H. Deterministic MST Sparsification in the Congested Clique[J]. oai:arXiv.org:1605.02022.
- [35] CHEN D H,ZHOU M,SUN Y Q,et al. MR-GSpar: A Distributed Large Graph Sparsification Algorithm Based on MapReduce [J]. Computer Science,2013,40(10):190-193. (in Chinese)  
陈德华,周蒙,孙延青,等. MR-GSpar: 一基于 MapReduce 的大图稀疏算法[J]. 计算机科学,2013,40(10):190-193.
- [36] BRYAN W. Sparsification of Social Networks Using Random Walks[D]. Orlando:University of Florida,2015.
- [37] LINDNER G,STAUDT C L,HAMANN M,et al. Structure-Preserving Sparsification of Social Networks[C]// IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining. ACM,2015:448-454.
- [38] FAN C,ZHAO W. A Sharp PageRank Algorithm with Applications to Edge Ranking and Graph Sparsification[M]// Algorithms and Models for the Web-Graph. Springer Berlin Heidelberg,2013:2-14.
- [39] KAPRALOV M,LEE Y T,MUSCO C,et al. Single Pass Spectral Sparsification in Dynamic Streams [C] // Proceedings of IEEE Foundations of Computer Science. New York: IEEE Press,2014:561-570.
- [40] MCGREGOR A. Graph stream algorithms;a survey[M]// Algorithms and Models for the Web-Graph. Springer Berlin Heidelberg,2014:9-20.
- [41] TANG N,CHEN Q,MITRA P. Graph Stream Summarization: From Big Bang to Big Crunch[C]// International Conference on Management of Data. ACM,2016:1481-1496.
- [42] MCGREGOR A. Graph Mining on Streams[M]. Springer US, 2009.
- [43] ASSADI S,KHANNA S,LI Y,et al. Dynamic Sketching for Graph Optimization Problems with Applications to Cut-Preserving Sketches[J]. Computer Science,2015(23):247-272.
- [44] EPPSTEIN D. Sparsification-a technique for speeding up dynamic graph algorithms[C]// Symposium on Foundations of Computer Science. IEEE Computer Society,1992:60-69.
- [45] KELNER J A. Spectral Sparsification in the Semi-streaming Setting[J]. Theory of Computing Systems,2013,53(2):243-262.
- [46] CALANDRIELLO D,LAZARIC A,VALKO M,et al. Incremental Spectral Sparsification for Large-Scale Graph-Based Semi-Supervised Learning[J]. Theory of Computing Systems, 2016(2):740-745.
- [47] MATHIOUDAKIS M,BONCHI F,CASTILLO C,et al. Sparsification of influence networks[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2011:529-537.
- [48] AHN K J,GUHA S. Graph Sparsification in the Semi-streaming Model[C]// International Colloquium on Automata, Languages and Programming. 2009:328-338.
- [49] KAPRALOV M,WOODRUFF D. Spanners and sparsifiers in dynamic streams[C]// Proceedings of the 2014 ACM symposium on Principles of Distributed Computing. ACM,2014:272-281.
- [50] AHN K J,GUHA S. Linear programming in the semi-streaming model with application to the maximum matching problem[C]// International Conference on Automata, Languages and Programming. 2011:526-538.
- [51] AHN K J,GUHA S,MCGREGOR A. Graph sketches: sparsification,spanners,and subgraphs[C]// ACM Sigmod-Sigact-Sigai Symposium on Principles of Database Systems. ACM,2012:5-14.
- [52] GOEL A,KAPRALOV M,POST I. Single pass sparsification in the streaming model with edge deletions[J]. Computer Science, 2012,3(2):740-745.
- [53] WANG W W,LI X P,FENG X C,et al. A Survey on Sparse Subspace Clustering[J]. Acta Automatica Sinica,2015,41(8): 1373-1384. (in Chinese)  
王卫卫,李小平,冯象初,等. 稀疏子空间聚类综述[J]. 自动化学报,2015,41(8):1373-1384.
- [54] GILBERT A,INDYK P. Sparse Recovery Using Sparse Matrices[J]. Proceedings of the IEEE,2008,98(6):937-947.
- [55] KAPRALOV M,LEE Y T,MUSCO C,et al. Single Pass Spectral Sparsification in Dynamic Streams [C] // Proceedings of IEEE Foundaions of Computer Science. New York: IEEE Prcess,2014:561-570.
- [56] LAI L,QIN L,LIN X,et al. Scalable subgraph enumeration in MapReduce[J]. Proceedings of the Vldb Endowment, 2015, 8(10):974-985.
- [57] AKIBA T,YANO Y. Compact and Scalable Graph Neighborhood Sketching[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2016: 685-694.