

基于改进的粗糙集和神经网络的 WSN 故障诊断

周 奚 薛善良

(南京航空航天大学计算机科学与技术学院 南京 211106)

摘 要 综合粗糙集理论和人工神经网络的优点,提出了改进的粗糙集理论算法,并结合人工神经网络,实现了一种无线传感器网络(Wireless Sensor Network, WSN)节点智能故障诊断方法。首先基于 WSN 的应用环境和故障特征的分析,通过数据采集、数据预处理和数据压缩来获得诊断决策表,并利用粗糙集中改进的归纳属性约简算法(Improved Inductive Attribute Reduction Algorithm, IIARA)对决策表进行属性约简,从而提取对故障诊断贡献最大的最小故障诊断特征集合,进而确定后端径向基函数神经网络(Radial Basis Function Neural Network, RBFNN)的拓扑结构。最后通过网络训练建立故障征兆与故障类型之间的非线性映射关系,得到诊断结果。仿真实验结果显示,该诊断算法在对 WSN 节点进行故障诊断时,可以有效地减少网络输入层个数,简化神经网络结构,减少网络的训练时间,提高模型的诊断准确性。

关键词 故障诊断,粗糙集,归纳属性约简算法,径向基函数,人工神经网络,无线传感器网络

中图法分类号 TP277 **文献标识码** A

WSN Fault Diagnosis with Improved Rough Set and Neural Network

ZHOU Xi XUE Shan-liang

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

Abstract Integrating the advantages of rough set theory and artificial neural network, improved rough set theory algorithm was proposed, and combined with artificial neural network, an intelligent fault diagnosis method of wireless sensor network (WSN) node was achieved. First, based on the analysis of application environment of WSN and fault characteristics, diagnosis decision table is obtained through data acquisition, data pretreatment and data compression, and is reduced by the improved inductive attribute reduction algorithm (IIARA) of rough set, thus the minimum fault diagnosis feature set is extracted which contributed most to the fault diagnosis, and then the topology of the radial basis function neural network (RBFNN) is determined. Finally, diagnosis results are obtained through the nonlinear mapping relationship between fault symptoms and fault types established by the network training. Simulation results show that at the time of fault diagnosis of WSN nodes, the diagnosis algorithm can effectively reduce network input layer, simplify the structure of neural network, reduce the training time of the network and improve the diagnosis accuracy of the models.

Keywords Fault diagnosis, Rough set, Inductive attribute reduction algorithm, Radial basis function, Artificial neural network, Wireless sensor network

1 引言

WSN 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。其通过与其它技术集成,将逻辑上的信息世界与客观上的物理世界融合在一起,以改变人类与自然界的交互模式。WSN 作为一种分布式计算平台,其节点易受各种干扰因素扰动而发生故障。当某些关键节点因故障失效时,将导致其周围一定区域内的节点的工作无法正常开展,进而会造成连通割断和网络覆盖漏洞的问题,降低节点的可靠性,影响 WSN 预定功能。为避免 WSN 故障由节点级恶化为网络级,必须对故障节点进行准确、及时的诊断,才能有效地给出修复方案,并及时修复以保证网络的正常运行。针对 WSN 节点智能化程度高、应用环境恶劣复杂、故障征兆

和故障种类多样,可以采用人工智能对其进行故障诊断。

WSN 的故障征兆具有相关性和多样性,而简单地根据故障征兆得到的故障类型的决策过程具有不相关性和模糊性。神经网络^[1,2]具有自学习、非线性模式识别、联想记忆和抗噪声干扰的能力,在故障诊断中^[3-7]得到广泛应用。但由于输入数据中信息的冗余情况、信息的有用与否及其作用大小的不确定性,同时不能简化输入信息空间维数,进而影响神经网络结构和训练样本的质量,造成神经网络的训练过度、训练时间过长。而粗糙集理论^[8]基于不可分辨关系思想,能在保证关键分类的前提下对数据进行约简,从而去除冗余属性和冗余样本,简化信息空间维数。因此,将神经网络方法与粗糙集理论方法混合集成,并用粗糙集理论约简决策表,去除冗余样本,提高训练样本质量,优化神经网络结构,从而提高诊断的

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;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。

准确性和降低训练的时间。本文基于上述思想,提出一种基于改进的粗糙集理论和人工神经网络的 WSN 节点智能故障诊断方法。

2 WSN 体系结构及故障类型分类

WSN 由 4 部分组成,分别是分布式传感器节点 (Sensor Node)、汇聚节点 (Sink Node)、互联网 (包括卫星) 和任务管理节点^[9-11]。WSN 体系结构如图 1 所示,通过随机部署,监控区域的大量传感器节点自组织形成多跳无线通信网络,通过传感器间的数据传递将检测信息和目标的相关信息沿着通信路径传送给汇聚节点或是处理能力、通信能力和存储能力更强的基站,再由汇聚节点或者基站通过互联网、卫星等方式将数据传送给任务管理节点。用户通过任务管理节点发送相应的控制命令,实现对被测对象的远程监控和实时操作。




图 1 WSN 体系结构 (实心表示选择的传输路径节点)

传感器节点故障分为硬故障和软故障^[12]。硬故障是指节点无法和网络中其它节点进行正常通信,引起的原因主要是节点损坏、节点布置远离其他节点和节点能量不足等。软故障是指节点虽然可以继续与其它节点进行通信,但是其与上层应用相关的工作状态异常。具体的故障类型可以分为电源模块故障、传感器模块故障、处理器模块故障和无线通信模块故障 4 类。

3 改进的粗糙集归纳属性约简算法 IIARA

归纳属性约简算法 (Inductive Attribute Reduction Algorithm, IARA) 对决策类提取条件属性集的关键子集,并利用核和约简的概念对各决策类进行冗余属性约简,从而得到决策表的最小决策规则^[13]。本文改进了基于粗糙集理论的归纳属性约简算法^[13],在该算法的基础上剔除冗余属性,以求得最小属性约简。

定义 1 设 $P = \{p_i | i = 1, \dots, k\}$ 为有限元素集合, $T_1(P) = \{\{p_i\} | p_i \in P\}$ 为集合 P 的一阶幂集; $T_2(P) = \{\{p_i, p_j\} | p_i \in P \wedge p_j \in P \wedge i \neq j\}$ 为集合 P 的二阶幂集; $T_i(P) (1 \leq i \leq k)$ 为集合 P 的 i 阶幂集,其中 $T_0(P) = \emptyset$ 。

定义 2 设 $P = \{p_i | i = 1, \dots, k\}$ 为有限元素集合, $T_1(P) = \{\{p_i\} | p_i \in P\}$ 为集合 P 的一阶幂集;对 $T_1(P)$ 中元素按某种属性重要性赋予权值, $\forall P' \in T_1(P), OT(P') = OT(p'_i), p_i \in P'$ 。按 $OT(P')$ 大小对 $T_1(P)$ 集合中的元素进行排序,得到一阶有序幂集 $T^1(P)$ 。同理, $T_i(P)$ 为集合 P 的 i 阶幂集,给 $T_i(P)$ 中元素赋予权值, $\forall P' \in T_i(P), OT(P') = \sum_{j=1, \dots, i} OT(p'_j), p_j \in P'$ 。按 $OT(p'_j)$ 大小对 $T_i(P)$ 中的元素进行排序,得到 i 阶有序幂集 $T^i(P)$ 。

定义 3 设决策表系统为 $S = \langle U, P \cup D, V, f \rangle$, 其中 $P = \{p_i | i = 1, \dots, k\}$ 为条件属性集, $D = \{d_1, d_2, \dots, d_l\}$ 为决策属

性集, l 是决策类型数量, V 是属性的值域, f 是一种映射,反映对象集合之间的值。

本文提出的改进的归纳属性约简算法如下:

第 1 步求取集合 P 的 D 核 $CORE_D(P)$:

(1) 令 $i=0, k=0, E$ 为空集, n 表示条件属性集 P 元素的个数;

(2) $p_i = P[i], p_i$ 表示条件属性集 P 第 i 个元素, 如果 $POS_{(P \setminus \{p_i\})}(D) = POS_P(D)$ 成立, 则 p_i 不是核属性, 转 (4), 否则转 (3);

(3) p_i 是核属性, $E(k) = P(i), k = k + 1$;

(4) $i = i + 1$;

(5) 如果 $i \geq n$, 转 (6), 否则转 (2);

(6) $CORE_D = E$;

(7) 结束。

第 2 步求取集合 P 的有序幂集:

对于有限元素集合 $P = \{p_i | i = 1, \dots, k\}$, 按照某种属性重要性度量方法得到重要性由大到小的一个排列 $p_1', p_2', \dots, p_k'$, 可以得到有序集 $P' = \{p_1', p_2', \dots, p_k'\}$, 其中 $OT(p_i') = 2^{k-i}$ 。其各阶有序幂集可分别求得:

集合 P 的一阶幂集为:

$$T_1(P) = \{\{p_i'\} | p_i' \in P\} \quad (1)$$

集合 P 的一阶有序幂集为:

$$T^1(P) = \{\{p_1'\}, \{p_2'\}, \dots, \{p_k'\}\} \quad (2)$$

集合 P 的二阶幂集为:

$$T_2(P) = \{\{p_i', p_j'\} | p_i' \in P \wedge p_j' \in P \wedge i \neq j \wedge p_i' \neq p_j'\} \quad (3)$$

集合 P 的二阶有序幂集为:

$$T^2(P) = \{\{p_1', p_2'\}, \{p_2', p_3'\}, \dots, \{p_{k-1}', p_k'\}\} \quad (4)$$

集合 P 的 i 阶幂集为:

$$T_i(P) = \{\{p_a', p_b', \dots, p_m'\} | p_a' \in P \wedge p_b' \in P \wedge \dots \wedge p_m' \in P \wedge a \neq b \wedge \dots \wedge b \neq m \wedge a \neq m \wedge p_a' \neq p_b' \wedge \dots \wedge p_a' \neq p_m' \wedge p_b' \neq p_m'\} \quad (5)$$

其中, 集合 $\{p_a', p_b', \dots, p_m'\}$ 中含有 i 个元素。

集合 P 的 i 阶有序幂集为:

$$T^i(P) = \{\{p_1', p_2', \dots, p_i'\}, \{p_2', p_3', \dots, p_{i+1}'\}, \dots, \{p_{k-i+1}', p_{k-i+2}', \dots, p_k'\}\} \quad (6)$$

第 3 步求取集合 P 的最小属性约简 $\min d_D(P)$:

(1) 令 $X = CORE_D(P), S = P \setminus X = \{p_1, p_2, \dots, p_n\}, T^i(S)$ 为 S 的 i 阶 ($1 \leq i \leq n$) 有序幂集;

(2) 令 $t = \log_2 l - (k - n)$, 如果 $t < 0, i = 0$, 则对 t 进行向上取整操作;

(3) 令 $flag = false, M = 0, N = 0$;

(4) $Y = T^t(H)$;

(5) 取 $y = Y(N)$, 表示取集合 Y 中第 N 个元素, $A = X \cup \{y\}$, 如果 $POS_{(A)}(D) = POS_P(D)$ 且 $flag = false$, 则 $B(M) = A, flag = true$, 如果 $POS_{(A)}(D) = POS_P(D)$ 且 $flag = true$, 则 $M = M + 1$, 则 $B(M) = A$;

(6) $Y = Y - \{y\}, N = N + 1$;

(7) 如果 $Y \neq \emptyset$, 转 (5);

(8) 如果 $flag = true$, 则 $\min d_D(P) = B$, 转 (11);

(9) $i = i + 1$, 如果 $i \leq m - 1$, 转 (4);

(10) $\min d_D(P) = P$;

(11) 结束。

IIARA 是一种效率较高的启发式搜索算法。在 IIARA 中,起始搜索空间是从属性核开始的,属性核是所有约简的交集,属性核包含在约简结果中。先得到属性核,可以减少部分重复搜索工作,从属性核开始,依次加入属性,直到得到约简结果。考虑到在应用场景中会对属性值进行离散化工作,其条件属性值变为 0 或 1,由计算机知识可知, n 位二进制最多有 2^n 种不同情况,反推,假设故障类型为 l 种,则至少对 $\log_2 l$ 向上取整的整数个属性可以分开这 l 种故障类型。对第 3 步的(2)中加入对 i 的控制以减小搜索空间;算法第 3 步的(5)中首先取得有序集中重要性较高的元素,以提高搜索效率,同时改进原算法得到属性的所有约简,为后续根据后发式贪心算法找到最优故障特征子集做准备;第 3 步(9)中利用对正域的理解,当任意 $k-1$ 个属性形成的正域都不等于 k 个属性形成的正域,则原所有知识是不可约简的,对第 3 步(9)中不等式加以改动,可减少不必要的正域判断。IIARA 缩小了搜索空间,提高了搜索的有效性,并且能够保证得到属性的所有约简,便于在知识获取不充足的情况下,也能有选择地利用已经存在的属性作出最佳决策。

4 集成 IIARA 和 RBF 神经网络的 WSN 故障诊断算法 IRSRBF

在 IIARA 的基础上,本文提出集成径向基函数神经网络的 WSN 节点智能故障诊断方法(Improved Rough Set Radical Basis Function,IRSRBF)。粗糙集作为 RBF 神经网络的前端处理系统,对故障样本进行预处理,去除冗余属性核重复样本,压缩数据,从而简化 RBF 神经网络结构。同时,RBF 神经网络通过对训练样本进行自学习,从而可以对测试样本进行智能地诊断 WSN 的各种定性故障,如图 2 所示,输出的诊断结果大于某阈值时,其表明出现相应的故障。




图 2 基于粗糙集和 RBF 神经网络的 WSN 节点智能故障诊断流程图

IRSRBF 算法工作流程如下:

(1)故障检测信息获取:Sink 节点采集被检测节点的数据,并用数字信号处理方法对原始信号进行处理,得到原始故障诊断样本。

(2)检测信息的简化与提取:通过数据采集与数据预处理后得到的原始故障诊断样本,利用粗糙集理论从数据样本中提取对诊断故障贡献最大的故障诊断特征值集合。经 Rough Sets 处理的数据作为 RBF 神经网络的输入数据被用以进行故障诊断。其中 Rough Sets 数据处理流程如图 3 所示。




图 3 Rough Sets 数据处理流程

①连续离散化:Rough Sets 首先对原始故障诊断样本中的连续数据进行离散化处理。再进行压缩重复样本的操作,即判断其中是否存在重复的样本,如果存在,则删除,以便得到简化的离散化故障诊断决策表。

②最小故障诊断特征提取:构建离散化故障诊断决策表。根据改进属性约简算法得到最小属性约简 $\text{mind}_D(P)$,输出最小故障诊断特征子集。

③智能故障诊断:首先根据 Rough Sets 数据处理后获取的最小故障诊断特征得到输入层单元个数、隐含层单元个数和输出层单元个数,从而确定 RBF 神经网络的初始拓扑结构;接着利用最小故障诊断特征相对应的训练样本训练 RBF 神经网络,无导师学习训练确定输入层与隐含层间的权值,有导师学习训练确定隐含层与输出层间的权值,建立故障特征与故障之间的映射;最后使用测试样本对 RBF 神经网络进行测试,得到故障诊断结果。

采用 IRSRBF 算法的优势:将 WSN 的故障诊断过程中的故障特征提取转换为求取约简,利用本文提出的 IIARA 算法能更快地求得属性所有约简,加速学习和分类的过程,提高故障分类的质量;利用求得的属性约简,简化样本及条件属性,简化了 RBF 神经网络结构,提高系统的效率和速度;利用神经网络良好的容错性和可扩展性,降低误报和漏报对故障诊断的影响。

5 仿真实验及结果分析

本节将分为 2 个实验,实验 1 对 IIARA 进行仿真实验,实验 2 对 IRSRBF 算法进行仿真实验。

5.1 实验 1——IIARA 算法

为了使问题简化,定义如下表述: P 代表条件属性, D 代表决策属性。

$p[1]$ 代表被测节点对发出的询问命令是否有响应, $p[1]=0$ (有), $p[1]=1$ (无);

$p[2]$ 代表被测节点定期是否有信号返回, $p[2]=0$ (有), $p[2]=1$ (无);

$p[3]$ 代表汇聚节点发出的指令是否被被测节点正确执行, $p[3]=0$ (是), $p[3]=1$ (否);

$p[4]$ 代表被测节点是否能传递其他节点的数据, $p[4]=0$ (是), $p[4]=1$ (否);

$p[5]$ 代表被测节点的温度值是否与平均值方差较大, $p[5]=0$ (是), $p[5]=1$ (否);

$p[6]$ 代表被测节点与邻居节点的温度值相差较大, $p[6]=0$ (是), $p[6]=1$ (否);

$p[7]$ 代表被测节点对重发询问命令是否有响应, $p[7]=0$ (是), $p[7]=1$ (否);

$p[8]$ 代表改变发射频率,发出询问命令是否有响应, $p[8]=0$ (是), $p[8]=1$ (否);

d_1 代表无故障; d_2 代表电源模块故障; d_3 代表传感器模块故障; d_4 代表处理器模块故障; d_5 代表无线通信模块故障。

建立 WSN 的节点故障征兆及其对应属性值表如表 1 所列,并利用上述定义将表 1 转化为表 2。

表 1 故障诊断决策表

决策属性	条件属性 P							
D	p[1]	p[2]	p[3]	p[4]	p[5]	p[6]	p[7]	p[8]
d_1	有	有	是	是	否	否	是	是
d_1	无	有	是	是	否	否	是	是
d_1	无	有	是	是	否	否	否	是
d_1	有	有	是	是	否	否	否	是
d_2	无	无	否	否	否	否	否	否
d_3	有	有	是	是	是	是	是	是
d_3	有	有	是	是	是	是	否	是
d_4	有	有	否	是	否	否	是	是
d_4	无	有	否	是	否	否	是	是
d_5	无	有	否	否	否	否	否	否

表 2 故障诊断决策表

决策属性	条件属性 P							
D	p[1]	p[2]	p[3]	p[4]	p[5]	p[6]	p[7]	p[8]
d_1	0	0	0	0	1	1	0	0
d_1	1	0	0	0	1	1	0	0
d_1	1	0	0	0	1	1	1	0
d_1	0	0	0	0	1	1	1	0
d_2	1	1	1	1	1	1	1	1
d_3	0	0	0	0	0	0	0	0
d_3	0	0	0	0	0	0	1	0
d_4	0	0	1	0	1	1	0	0
d_4	1	0	1	0	1	1	0	0
d_5	1	0	1	1	1	1	1	1

对 IARA 和 IIARA 算法,使用处理器为 Intel i7 2.5 GHz,内存为 8G 的 Hasee 笔记本电脑在 Matlab2012a 环境下进行仿真实验。利用文献[13]中的 IARA 只得到一个约简结果 $\{p[2], p[3], p[4], p[5]\}$,而利用改进的归纳属性约简算法可以得到下面的故障属性约简:

$\{p[2], p[3], p[4], p[5]\}, \{p[2], p[3], p[4], p[6]\}, \{p[2], p[3], p[5], p[7]\}, \{p[2], p[3], p[5], p[8]\}, \{p[2], p[3], p[6], p[7]\}, \{p[2], p[3], p[6], p[8]\}$

由上述约简结果可知,IARA 的故障属性约简结果包含在 IIARA 算法所获得的故障属性约简集合中。对这两种算法进行效率比对,比较在上述运行环境下运行 50 次的平均时间。运行 50 次平均时间对比如表 3 所列。

表 3 原算法与改进算法的用时对比表

算法	平均每次用时(s)
IARA	0.1665
改进的归纳属性约简算法	0.1543

由表 3 可知,在原归纳属性约简算法只求一种约简,而改进的算法计算出所有约简的前提下,改进算法的用时小于原算法,效率提高了 7.90%。改进的算法是一种效率较高的启发式算法,是一种基于对属性组合的搜索,可以通过减小搜索的空间来提高搜索的效率。

5.2 实验 2——WSN 节点故障诊断算法

现对图 1 中检测区域的温度进行检测,设 $S=\{U, P \cup D\}$ 为图 1 中 WSN 监测系统的子节点故障诊断决策表系统, U 为论域,其中集合中元素对应被诊断节点对象, P 为条件属性集,对应于点故障征兆集, D 为决策属性集,对应于子节点故

障类型。结合监测系统的特点和运行方式,建立 WSN 如表 4 所列的 WSN 节点故障征兆及其属性值表和如表 5 所列的 WSN 节点故障类型及其对应征兆表。

表 4 WSN 节点故障征兆及其属性值表

属性	故障征兆属性	属性值
p_1	被测节点是否连续 n 个周期以上无信息返回	$p_1=0$ (是), $p_1=1$ (否)
p_2	被测节点是否定期有信息返回	$p_2=0$ (是), $p_2=1$ (否)
p_3	被测节点是否能响应汇聚节点的询问命令	$p_3=0$ (是), $p_3=1$ (否)
p_4	改变发射频率,发出询问命令是否有响应	$p_4=0$ (是), $p_4=1$ (否)
p_5	汇聚节点发出的指令是否被被测节点正确执行	$p_5=0$ (是), $p_5=1$ (否)
p_6	温度是否恒为 0	$p_6=0$ (是), $p_6=1$ (否)
p_7	温度信息是否恒定	$p_7=0$ (是), $p_7=1$ (否)
p_8	被测节点是否能传递其他节点的数据	$p_8=0$ (是), $p_8=1$ (否)
p_9	被测节点能量是否低于设定警戒值	$p_9=0$ (是), $p_9=1$ (否)
p_{10}	被测节点是否出现在其他节点的邻居路由表中	$p_{10}=0$ (是), $p_{10}=1$ (否)

表 5 WSN 节点故障类型及其对应征兆表

故障编号	故障类型	对应故障征兆
1	无故障	
2	电源故障	$p_1 \cdot p_2 \cdot p_3 \cdot p_4 \cdot p_5 \cdot p_8 \cdot p_9 \cdot p_{10}$
3	无线通信故障	$p_1 \cdot p_2 \cdot p_3 \cdot p_4 \cdot p_5 \cdot p_8$
4	处理器故障	$p_1 \cdot p_2 \cdot p_3 \cdot p_5 \cdot p_8$
5	传感器故障	$p_6 \cdot p_7$

根据表 4 和表 5,建立一个 WSN 节点故障样本决策表,如表 6 所列。

表 6 WSN 节点故障样本决策表

U	条件属性 p										d
	p_1	p_2	p_3	p_4	p_5	p_6	p_7	p_8	p_9	p_{10}	
1	0	0	0	0	0	0	0	0	0	0	1
2	1	1	1	1	1	1	0	0	1	1	2
3	0	1	0	0	0	0	0	0	1	0	2
4	1	1	1	1	1	0	0	0	0	0	3
5	1	1	1	1	1	0	0	1	0	0	3
6	1	1	1	0	1	0	0	1	0	0	4
7	0	1	1	0	1	0	0	0	0	0	4
8	0	0	0	0	0	0	0	0	0	1	5
9	0	0	0	0	0	0	0	0	1	0	5
10	0	0	0	0	0	0	0	0	1	1	5

调用 IIARA 对决策表进行约简处理,获得相对应的最小条件属性约简 $\{p_4, p_5, p_8, p_9, p_{10}\}$,在保持与原决策表相同分类能力的情况下,去除冗余属性,再通过数据压缩,去除重复的对象,使原决策表变得更简洁,约简压缩后的故障决策表如表 7 所列。

表 7 约简压缩后的 WSN 节点故障诊断决策表

对象集 U	条件属性 p					决策属性 d
	p_4	p_5	p_8	p_9	p_{10}	
1	0	0	0	0	0	1
2	0	0	0	0	1	5
3	0	0	0	1	0	2
4	0	0	0	1	1	5
5	0	1	1	0	0	4
6	1	1	0	0	0	3
7	1	1	1	0	0	3
8	0	0	0	1	0	2
9	0	1	0	0	0	4

按照 IRSRBF 算法将约简前的数据(见表 6)和约简后的数据(见表 7)构建常规 RBF 神经网络、文献[14]中提出的粗糙集-BP 神经网络以及本文的 IRSRBF 神经网络。对于上述 3 种网络,通过调节扩展常数 spread 和隐藏层节点数来获得最佳的网络结构参数。本文中,常规 RBF 神经网络的扩展常

数取 1.8,输入神经元个数为 9,隐藏层节点数为 6,输出神经元数为 5,构成 9-6-5 的网络结构。文献[14]中提出的粗糙集-BP 神经网络的扩展常数取 1.8,输入神经元个数为 9,隐藏层节点数为 7,输出神经元个数为 6,构成 9-7-6 的网络结构。本文的 IRSRBF 神经网络的扩展常数取 1.8,输入神经元个数为 5,隐藏层节点数为 5,输出层神经元个数为 5,构成 5-5-5 的网络结构。网络的故障判断阈值取 0.5,网络输出如果高于 0.5,则判定出现故障。

将节点故障样本作为测试样本,比较 3 种诊断方法的效果,诊断结果如表 8 所列。从表中可以看到,3 种方法都可以得到正确的诊断结果。但是 3 种方法相比较,本文提出的 IRSRBF 神经网络经过改进的归纳属性约简后,只选取对故障诊断起重要作用的条件属性,使得神经网络的结构明显比其它两种方法的网络结构简单,训练时间更短,诊断结果的准确性更高。

表 8 常规 RBF,文献[14]方法和 IRSRBF 诊断结果对比表

故障类型	常规 RBF 神经网络的诊断结果	文献[14]方法的诊断结果	IRSRBF 神经网络的诊断结果
1	0.1255	0.1048	0.1000
2	0.1916	0.1455	0.1255
3	0.1000	0.1002	0.1000
4	0.6810	0.9120	0.9005
5	0.3120	0.2110	0.1005

图 4 是 IRSRBF 诊断算法与文献[14]中的同类诊断算法和常规 RBF 诊断算法的诊断结果比较。从图中可以看出 IRSRBF 的正确率在不同数据可靠性下,均比其它两种算法的正确率要高。并且当数据精度下降时,正确率的差值进一步扩大即表示数据可靠性越低,IRSRBF 算法越能保证正确率。分析其原因,故障诊断的实质是一个搜索属性的过程,由于 WSN 数据很难得到 100%的可靠性保证,常规 RBF 神经网络和同类方法在诊断时需要依赖的属性较多,其可靠性被分散在众多的数据上,导致可靠性下降。本文提出的 IRSRBF 算法通过数据属性约简减小搜索的空间,有效地避免了众多冗余属性对故障诊断正确性的干扰;同时利用 RBF 神经网络对噪声的不敏感性,抗干扰能力强的特征,进一步提高了诊断的正确率。




图 4 IRSRBF 与同类方法和 RBF 诊断结果比较

结束语 本文提出了改进的归纳属性约简算法 IIARA,并集成 RBF 神经网络,提出 WSN 故障诊断算法 IRSRBF。IRSRBF 算法能够在 WSN 节点信息不完整或者部分信息有误的情况下进行有效地故障诊断,特别是当数据的可靠性下降时,该算法在诊断速度和诊断精度上优势更大,提高了诊断系统的可靠性和 WSN 的实用性。

参考文献

- [1] 朱大奇,史惠. 人工神经网络原理及应用[M]. 北京:科学出版社,2006:33-56
- [2] 韩力群. 人工神经网络教程[M]. 北京:北京邮电学院出版社,2006
- [3] Zhu Liang, He Fei, Tong Yi-fei, et al. Fault detection and diagnosis of belt weigher using improved DBSCAN and Bayesian regularized neural network[J]. Mechanika, 2015, 21(1): 70
- [4] Tayyab W, Mustafa D, Cemal K. Fault Diagnosis on Bevel Gear-box with Neural Networks and Feature Extraction[J]. Electronics & Electrical Engineering, 2015, 21(5): 69-74
- [5] Xiong Guo-jiang, Shi Dong-yuan, Chen Jin-fu, et al. Divisional fault diagnosis of large-scale power systems based on radial basis function neural network and fuzzy integral[J]. Electric Power Systems Research, 2013, 105: 9-19
- [6] 熊国江,石东源,朱林,等. 基于径向基函数神经网络的电网模糊元细胞故障诊断[J]. 电力系统自动化, 2014, 38(5): 59-65
- [7] Yan Jun, Jiang Xun-lin, Cheng Hai-song, et al. A hybrid training method for ANNs and its application in multi faults diagnosis of rolling bearing[J]. Journal of Vibroengineering, 2015, 17(7): 3538-3550
- [8] Pawlak Z. Rough sets [J]. International Journal of Computer and Information Science, 1982, 11(5): 341-355
- [9] Akyildiz I F, Su W, Sankarasubramanian Y. Wireless sensor networks: a survey[J]. Computer Networks, 2002, 38(4): 393-422
- [10] 孙利民,李建中,陈渝,等. 无线传感器网络[M]. 北京:清华大学出版社,2008
- [11] Noury N, Herve T, Riale V, et al. Monitoring behavior in home using a smart fail sensor[C]// IEEE-EMBS Special Topic Conference on Microtechnologies in Medicine and Biology. Lyon: IEEE Computer Society, 2000: 607-610
- [12] Basile C, Gupta M, et al. An approach for detecting and distinguishing errors versus attacks in sensor networks [C]// Proceedings of the 2006 International Conference on Dependable Systems and Networks. 2006: 474-484
- [13] 王国胤. 粗糙集理论与知识获取[M]. 西安:西安交通大学出版社,2001:1-155
- [14] 尚志信,周宇. 基于粗糙集和 BP 神经网络算法的网络故障诊断模型研究[J]. 宁波大学学报(理工版), 2013, 26(2): 45-48

(上接第 20 页)

- [25] Zhang R, Lin Y. DEG 5.0, a database of essential genes in both prokaryotes and eukaryotes[J]. Nucleic Acids Res, 2009, 37(1): 455-458
- [26] Saccharomyces Genome Deletion Project[OL]. <http://www.sequence.stanford.edu/group>
- [27] Jeong H, Mason S P, Barabasi A L, et al. Lethality and centrality in protein networks[J]. Nature, 2001, 411(6833): 41-42

- [28] Wuchty S, Stadler P F. Centers of complex networks[J]. Journal of Theoretical Biology, 2003, 223(1): 45-53
- [29] Lin C Y, Chin C H, Wu H H, et al. Hubba: hub objects Analyzer-a framework of interactome hubs identification for network biology[J]. Nucleic Acids Res, 2008, 36(2): 438-443
- [30] Li M, Wang J X, Chen X, et al. A local average connectivity-based method for identifying essential proteins from the network level[J]. Computational Biology & Chemistry, 2011, 35(3): 143-150