

文章编号: 1000-8152(2001)05-0681-05

## 粗糙集神经网络系统在故障诊断中的应用\*

郝丽娜

徐心和

(东北大学机械工程与自动化学院·沈阳, 110004) (东北大学控制仿真中心·沈阳, 110004)

**摘要:** 故障诊断中的误报和漏报现象直接影响诊断的准确率,同时在线故障诊断又要求很强的实时性.本文在给出粗糙集神经网络系统原理框图的基础上,结合领域知识把该系统应用于滚动轴承的故障诊断中,仿真实验结果表明该系统提高了故障诊断的准确率和诊断速度,同时减少了检测项目,降低了诊断成本,在实际中有良好的应用前景

**关键词:** 粗糙集; 人工神经网络; 故障诊断

**文献标识码:** A

## The Application of Rough Set Neural Network System in Fault Diagnosis

HAO Lina

(The College of Mechanical Engineering and Automation, Northeastern University · Shenyang, 110004, P. R. China)

XU Xinhe

(Control and Simulation Research Center, Northeastern University · Shenyang, 110004, P. R. China)

**Abstract:** The phenomena of misinformation and failing to report in fault diagnosis affect directly the quality of diagnosis, meanwhile, fault diagnosis on-line demands real time. On the basis of giving an architecture of rough set neural network system, this paper applies it to the fault diagnosis of rolling bearings combined with professional knowledge. Simulation results indicate that the system has increased the quality and rate of diagnosis, reduced measure items and costs of diagnosis. There will be well application prospect in practice.

**Key words:** rough sets; artificial neural networks; fault diagnosis

### 1 引言(Introduction)<sup>[1-3]</sup>

粗糙集(rough sets, RS)理论是一种刻画不完整性和不确定性的数学工具,能有效地分析和处理不精确、不一致、不完整等各种不完备信息,并从中发现隐含的知识,揭示潜在的规律.在RS理论中,“知识”被认为是一种将现实或抽象的对象进行分类的能力.关于论域的某种知识,使用属性及其值来描述论域中的对象.RS理论中应用决策表来描述论域中对象,它是一张二维表格,每一行描述一个对象,每一列描述对象的一种属性,属性分为条件属性和决策属性.论域中的对象根据条件属性的不同,被划分到具有不同决策属性的决策类中.对于分类来说,并非所有的条件属性都是必要的,有些是多余的,去除这些属性不会影响原来的分类效果.从另一个角度看,决策表中每一个对象都蕴含着一条决策规则,决策表实际上也是一组逻辑规则的集合.约简定义为不含多余属性并保证分类正确的最小条件属性集.

一个决策表可能同时存在几个约简,这些约简的交集定义为决策表的核,核中的属性是影响分类的重要属性.“约简”和“核”这两个概念很重要,是RS方法的精华.RS理论提供了搜索约简和核的方法.

#### 1.1 粗糙集理论的特点(Characteristics of rough sets)

1) RS不需要先验知识.模糊集和概率统计方法是处理不确定信息的常用方法,但这些方法需要一些数据的附加信息或先验知识,如模糊隶属函数和概率分布等,这些信息有时并不容易得到.RS分析方法仅利用数据本身提供的信息,无须任何先验知识.

2) RS是一个强大的数据分析工具.它能表达和处理不完备信息,以不可分辨关系为基础,侧重分类;能在保留关键信息的前提下对数据进行化简并求得知识的最小表达;能识别并评估数据之间的依赖关系,揭示出概念简单的模式;能从经验数据中获取易于证实的规则知识.

\* 基金项目:西安交通大学机械制造系统工程国家重点实验室开放基金资助项目.

收稿日期:2000-07-07; 收修改稿日期:2000-10-17.

### 1.2 粗糙集理论的应用(Applications of rough sets)

RS理论的生命力在于它具有较强的实用性,自20世纪80年代诞生以来,已经在许多领域取得了令人鼓舞的成果.如:医疗诊断、股票数据分析、模式识别、地震预报、冲突分析、数据库中的知识发现、粗糙控制、过程控制、专家系统、人工神经网络、决策分析、近似推理、软件工程数据分析、图象处理、材料科学中的晶体结构分析、预测建模、结构建模、投票分析、电力系统和轴承故障诊断等.

### 1.3 人工神经网络(ANN)的特点与应用(Characteristics and applications of artificial neural networks)

由于人工神经网络具有处理复杂模式及进行联想、推测和记忆的功能,并且有良好的容错性和扩展性,在实际中得到广泛应用.但训练时间过于漫长的固有缺点是制约ANN实用化的因素之一.

本文在综合RS和ANN的基础上,给出了粗糙集神经网络(RNN)系统框图,并把该系统应用于轴承的故障诊断中,用MATLAB进行了仿真实验,并把计算结果与有关文献相比较.下面分别介绍该系统的工作原理和应用举例,并给出有关结论.

## 2 粗糙集神经网络系统构成(The structure of rough set neural network system)

RNN系统框图如下所示:

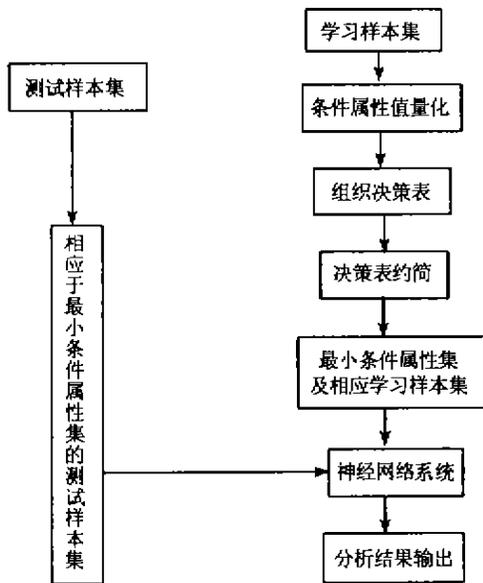


图1 粗糙集神经网络系统框图

Fig.1 Architecture of rough set neural networks system

各个部分工作原理为:

1) 学习样本集.从收集的原始数据中产生;数据的多少取决于许多因素,如神经网络的大小,测试

的需要及输入输出的分布等.其中网络大小最为关键,通常较大的网络需要较多的训练数据.影响数据多少的另一个因素是输入模式和输出结果的分布,对数据预先加以分类可以减少所需的数据量.相反,数据稀薄不匀甚至相互覆盖则势必要增加数据量.

2) 条件属性值量化.RS方法是一类符号化分析方法,需要将连续的变量离散化,常用的方法有:Pawlak Z提出的粗糙函数的概念<sup>[4]</sup>;神经网络方法<sup>[5]</sup>;利用相关的领域知识<sup>[6]</sup>;求出与各技术状态等级相对应的征兆临界值,以该数值为分界值对样本数据进行量化.

3) 组织决策表.采用量化后的属性值形成一张二维表格,每一行描述一个对象,每一列描述对象的一种属性,属性分为条件属性和决策属性.

4) 决策表约简.包括①条件属性简化:去掉某一属性后,考察决策表的相容性,如果去掉该属性后决策表是相容的,就去掉该属性,直到决策表最简单为止;②决策规则简化:在条件属性简化后的决策表中,去掉样本集中的重复信息,考察剩下的训练集,每一条规则中哪些属性值是冗余的,去掉冗余信息和重复信息后,就得到最小决策算法.当然也可以先简化每一决策规则,再简化条件属性,从而得到最小条件属性集.

5) 最小条件属性集及相应学习样本:采用约简得到的最小条件属性集及相应的原始数据重新形成新的学习样本集.该样本集除去了所有不必要的条件属性,仅保留了影响分类的重要属性.

6) 神经网络系统<sup>[7,8]</sup>.用约简后形成的学习样本对神经网络进行学习和训练.由于在模式分类、特征提取等应用中,神经网络主要作用是函数映射,所以可以选用BP网络、ART1网络、自组织特征映射、径向基函数网络(radial basis function简称RBF)和学习向量量化(LVQ)神经网络等.在人工神经网络中,学习规则就是修正权值的一个算法,目前神经网络学习规则有三类:相关规则,纠错规则和无教师学习规则.通过使用合适的学习规则可以获得合适的映射函数或希望输出,提高系统的性能.最后输入按照最小条件属性集及相应的原始数据重新形成的测试样本集,对网络进行测试,输出分类结果.

## 3 应用举例(Application example)

用粗糙集神经网络系统进行轴承故障诊断,采用文献[6]中的数据表1,并与文中采用RS方法得到的结果进行比较.具体步骤为:

1) 利用条件属性之间的依赖性,去掉所有可省

略的条件属性,即表 1 中的  $s_3, s_4, s_{11}, s_{12}$ , 此时表 1 中的条件属性有:  $s_1, s_2, s_5, s_6, s_7, s_8, s_9, s_{10}$ ;  $D$  为决策属性。

2) 利用 L 方法的四个临界值  $b_1, b_2, b_3$ , 和  $b$  (见文献[6]中表 2), 把样本(文献[6]中表 1)中的每一个属性值进行量化, 方法是把  $(0, b_1]$  区间的属性值量化为 1;  $(b_1, b_2]$  区间的属性值量化为 2;  $(b_2, b_3]$  区间的属性值量化为 3;  $(b_3, b_4]$  区间的属性值量化为 4;  $(b_4, b_5]$  区间的属性值量化值 5, 得到一个决策表; 表中样本 26 与样本 41 不相容, 可视样本 41 为噪音数据. 因为用 LVQ 网络及 BP 网络仿真表明: 去掉样本 41 后不影响正确率, 且样本 41 的诊断结果也正确。

3) 利用知识的充分性理论对样本进行简化, 消去样本集中的重复信息; 如: 样本 2 (与样本 10 重复); 样本 4 (与样本 3 重复); 样本 16, 34 (与样本 5 重复); 样本 6, 18, 19, 20, 21, 22, 24, 25 (与样本 7 重复); 样本 13 (与样本 9 重复); 样本 31 (与样本 30 重复); 样本 55 (与样本 48 重复); 注意: 保留的样本不影响属性值区间, 如样本 2 的  $s_1$  属性值为 97.2, 而样本 10 的  $s_1$  属性值为 89.4, 故保留样本 10 为学习样本, 其它以此类推。

4) 对条件属性进行简化; 得到核为  $\{s_7, s_8, s_9\}$ ; 原因是如果去掉属性  $s_7$ , 则有样本 26 与样本 27 不

相容; 如果去掉属性  $s_8$ , 则有样本 26 与样本 42 不相容; 如果去掉属性  $s_9$ , 则有样本 1 与样本 27 不相容;

5) 求出最小条件属性集; 有  $\{s_2, s_6, s_7, s_8, s_9\}$ ,  $\{s_6, s_7, s_8, s_9, s_{10}\}$ ,  $\{s_1, s_7, s_8, s_9, s_{10}\}$ ;

6) 根据最小条件属性和相应的原始数据, 形成新的学习样本集;

7) 采用 LVQ 神经网络进行训练和测试, 神经元个数为学习样本数; 学习规则使用从 Kohonen 学习规则发展而来的 LVQ 学习规则. 分别针对全部属性和最小条件属性集采用 LVQ 神经网络对表 1 的一组学习样本和表 2 所示测试样本进行训练和测试, 比较各组结果如表 3 所示。

可以看出采用本文的 RNN 方法比文献[6]的 RS 方法准确率高; 用最小条件属性训练的系统比用全部属性集训练的系统准确率高, 速度快; 系统性能与所选择的样本质量有关, 因为用全部属性训练的系统中有噪音数据的干扰, 所以准确率降低; 噪音数据产生的原因有: 数据误报、测量误差等. 又由于采用神经网络方法对学习样本进行训练, 因为神经网络有很好的容错性和扩展性, 对漏报数据有一定的处理能力。

下面是表 1, 参见文献[6]中的表 1, 采用的样本为: 1, 3, 5, 7 ~ 12, 14, 15, 17, 23, 26 ~ 30, 32, 33, 35 ~ 40, 42 ~ 54。

表 1 学习样本集  
Table 1 Learning samples

No.	s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	s12	D
1	97.0	85.8	1.4	0.4	8.0	17.0	31.0	30.0	17.0	24.0	36.2	42.0	0
3	109.6	99.0	6.0	1.8	34.0	43.0	120.0	110.0	56.0	53.0	136.7	129.5	0
5	109.2	95.0	5.8	1.1	28.0	36.0	95.0	95.0	48.0	43.0	110.1	110.3	1
7	97.8	95.0	1.6	1.1	4.5	6.5	11.5	9.5	8.5	8.5	15.0	14.3	0
8	97.2	82.6	1.4	0.3	9.5	14.5	31.0	22.0	23.0	17.0	39.8	31.4	0
9	97.9	85.4	1.6	0.4	6.5	7.5	23.0	16.5	14.5	10.5	28.0	20.9	0
10	89.4	85.1	0.6	0.4	7.5	8.0	26.5	17.0	14.5	11.0	31.1	21.8	0
11	103.6	92.1	3.0	0.8	17.0	23.0	65.0	45.0	31.0	27.0	74.0	57.3	1
12	109.0	104.4	5.6	3.3	22.0	27.0	75.0	55.0	36.0	37.0	86.1	71.6	1
14	101.7	94.8	2.4	1.1	9.5	8.5	29.0	14.0	17.5	15.0	35.2	22.2	0
15	107.1	96.7	4.5	1.4	20.0	29.0	78.0	75.0	40.0	40.0	89.9	89.8	1
17	114.0	113.3	10.0	9.2	32.0	55.0	150.0	130.0	58.0	80.0	164.0	162.2	0
23	95.1	73.9	1.1	0.1	7.8	1.3	17.5	3.8	22.5	1.8	29.6	4.4	0
26	97.1	82.0	1.4	0.3	9.5	11.5	37.0	13.5	23.0	12.5	44.6	21.7	0
27	100.8	86.4	2.2	0.4	12.0	23.0	35.0	35.0	28.0	37.0	46.4	55.9	1
28	107.1	92.4	4.5	0.8	23.0	28.0	95.0	80.0	32.0	42.0	102.8	94.6	1
29	107.5	100.1	4.7	2.0	22.0	25.0	80.0	80.0	45.0	37.0	94.4	91.6	1
30	99.9	95.3	2.0	1.2	5.6	11.0	16.5	17.0	9.5	15.5	19.8	25.5	0
32	98.3	94.8	1.6	1.1	10.0	23.5	26.5	30.0	21.5	32.0	35.6	49.8	0

续表 1

No.	s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	s12	D
33	100.4	97.1	2.1	1.4	12.0	23.0	30.0	33.0	20.5	38.0	38.3	55.3	1
35	108.4	95.0	5.3	1.1	30.0	65.0	105.0	90.0	55.0	45.0	122.3	119.8	0
36	106.0	91.0	4.0	0.7	33.0	30.0	90.0	100.0	70.0	56.0	118.7	118.5	0
37	104.0	91.0	3.2	0.7	28.0	30.0	90.0	70.0	46.0	50.0	104.9	91.1	1
38	103.0	92.0	2.8	0.8	23.0	25.0	75.0	40.0	37.0	47.0	86.7	66.6	1
39	102.0	91.0	2.5	0.7	22.0	23.0	56.0	48.0	34.0	48.0	69.1	71.7	1
40	100.0	88.0	2.0	0.5	14.0	16.0	54.0	46.0	22.0	38.0	60.0	61.8	1
42	102.0	90.0	2.5	0.6	18.0	20.0	48.0	54.0	34.0	30.0	61.5	64.9	1
43	103.0	92.0	2.8	0.8	15.0	26.0	48.0	52.0	28.0	42.0	57.6	71.7	1
44	108.0	99.0	5.0	1.8	32.0	68.0	160.0	140.0	66.0	130.0	176.0	202.8	0
45	112.0	114.0	8.0	10.0	32.0	52.0	110.0	100.0	58.0	66.0	128.4	130.6	0
46	95.0	84.0	1.1	0.3	8.0	15.0	26.0	36.0	22.0	34.0	35.0	51.7	0
47	101.0	96.0	2.2	1.3	9.5	44.0	54.0	110.0	25.0	92.0	60.3	150.0	0
48	104.0	96.0	3.2	1.3	20.0	34.0	76.0	92.0	38.0	72.0	87.3	121.7	1
49	104.0	92.0	3.2	0.8	22.0	13.0	76.0	46.0	40.0	28.0	88.7	55.4	0
50	111.0	102.0	7.1	2.5	44.0	66.0	220.0	210.0	92.0	110.0	242.5	246.1	0
51	112.0	100.0	8.0	2.0	36.0	64.0	170.0	180.0	84.0	110.0	193.0	220.4	0
52	101.0	94.0	2.2	1.0	24.0	48.0	42.0	82.0	36.0	6.0	60.3	121.7	0
53	103.0	93.0	2.8	0.9	14.0	34.0	50.0	66.0	34.0	54.0	62.1	91.8	1
54	104.0	98.0	3.2	1.6	28.0	25.0	82.0	94.0	42.0	54.0	96.3	111.3	1

下面是表 2, 参见文献[6]表 1, 采用的样本为: 2, 4, 6, 13, 16, 18 ~ 22, 24, 25, 31, 34, 41, 55.

表 2 测试样本集

Table 2 Testing samples

No.	s1	s2	s3	s4	s5	s6	s7	s8	s9	s10	s11	s12	D
2	97.2	83.1	1.4	0.3	11.0	22.0	25.0	21.0	14.0	15.0	30.7	33.9	0
4	109.5	97.5	6.0	1.5	33.0	42.0	165.0	115.0	58.0	55.0	178.0	134.2	0
6	92.9	82.6	0.9	0.3	5.5	7.5	17.0	12.5	12.5	12.5	21.8	19.2	0
13	97.7	86.3	1.5	0.4	8.5	14.5	22.5	17.0	15.0	13.0	28.3	25.9	0
16	107.7	97.7	4.9	1.5	23.0	31.0	95.0	75.0	46.0	43.0	108.0	91.8	1
18	94.2	79.4	1.0	0.2	6.3	2.8	14.5	5.2	15.5	4.5	22.1	7.4	0
19	94.4	75.8	1.0	0.1	6.5	3.1	11.5	5.7	18.0	4.2	22.3	7.7	0
20	94.9	77.6	1.1	0.2	6.0	4.5	12.5	6.8	20.5	5.5	24.7	9.8	0
21	95.3	78.8	1.2	0.2	6.3	3.7	15.0	4.8	21.0	5.5	26.6	8.2	0
22	93.0	71.7	0.9	0.1	8.5	1.1	17.0	3.5	22.0	1.8	29.1	4.1	0
24	94.3	76.8	1.0	0.1	6.3	2.8	11.0	5.5	19.5	4.8	23.3	7.8	0
25	95.1	76.6	1.1	0.1	6.5	2.5	12.0	5.5	11.5	4.5	17.8	7.5	0
31	102.4	102.1	2.6	2.5	5.0	17.0	17.0	25.5	9.5	26.5	20.1	40.5	0
34	107.7	97.3	4.9	1.5	27.0	33.0	90.0	81.0	47.0	46.0	105.1	98.8	1
41	100.0	89.0	2.0	0.6	13.0	19.0	56.0	34.0	30.0	27.0	64.8	47.4	1
55	103.0	104.0	2.8	3.2	20.0	27.0	76.0	76.0	38.0	52.0	87.3	96.0	1

表 3 结果比较

Table 3 Results of comparison

属性项	文献[6]中	本文
	RS 方法	RNN 方法
	准确率	准确率
s1, s2, s5 ~ s12	93%	98.2%
s1, s2, s5, s6, s7, s8, s9, s10	*	98.2%
s2, s6, s7, s8, s9	*	100%
s6, s7, s8, s9, s10	*	100%
s1, s7, s8, s9, s10	*	100%

\* 文献[6]P149;注意,用最小子集从系统 s1 中不可能使对象的分类质量为最大值(等于1)。

#### 4 结论(Conclusions)

该系统综合了粗糙集理论和神经网络原理的优点:

① 利用粗糙集理论化简样本及条件属性,使得神经网络的输入端数量大大减少,简化了神经网络结构,提高了系统的速度;

② 通过粗糙集理论对条件属性求核,较好地消除了样本中噪音数据的干扰,提高了系统的准确率;

③ 采用该系统进行故障诊断,由于条件属性项大大减少,使得系统工作成本降低,诊断速度加快,实时性增强;

④ 由于神经网络有良好的容错性和扩展性,能有效地消除故障诊断中的误报和漏报现象。

使用该系统的注意事项:

① 系统性能与所选择的学习样本质量有关;

② 由于该系统在属性量化中采用了相关的领域

知识,当诊断对象变化时,该部分应做相应的调整。

#### 参考文献(References)

- [1] Han Zhenxiang, Zhang Qi and Wen Fushuan. A survey on rough set theory and its application [J]. Control Theory and Applications, 1999, 16(2): 153 - 157 (in Chinese)
- [2] Wang Jue, Miao Duoqian and Zhou Yujian. Rough set theory and its application: A survey [J]. Pattern Recognition and Artificial Intelligence, 1996, 9(4): 337 - 344 (in Chinese)
- [3] Zeng Huanglin. Rough Set Theory and Its Application [M]. Chongqing: Chongqing University Press, 1998 (in Chinese)
- [4] Pawlak Z. Rough sets, rough relations and rough functions [J]. Fundamenta Informaticae, 1996, 27(2,3): 103 - 108
- [5] Chen Zunde. Intelligent system combined rough set with artificial neural network and its application [J]. Pattern Recognition and Artificial Intelligence, 1999, 12(1): 1 - 5 (in Chinese)
- [6] Ryszard Nowicki. Evaluation of vibroacoustic diagnostic symptoms by means of the rough sets theory [J]. Computers in Industry, 1992, 20(2): 141 - 152
- [7] Jiao Licheng. Neural Network Computation [M]. Xi'an: Xi'an Electronic Science & Technology University Press, 1996 (in Chinese)
- [8] Lou Shuntuan and Shi Yang. System Analysis and Design Based on MATLAB - Neural Network [M]. Xi'an: Xi'an Electronic Science & Technology University Press, 1998 (in Chinese)

#### 本文作者简介

郝丽娜 1968年生,东北大学在职博士生,主要研究方向为智能系统及应用, CIMS 工程应用等

徐心和 1940年生,东北大学教授,博士生导师,主要研究方向为离散事件动态系统与混合系统,计算机控制与仿真,混合系统,人工智能与机器人学等。

(上接第 680 页)

- [5] Fang Jian and Xi Yugeng. Static scheduling for job shop based on genetic algorithm [J]. Journal of Shanghai Jiaotong University, 1997, 31(3): 49 - 52
- [6] Bernd Gross and Peter Roosen. Total process optimization in chemical engineering with evolutionary algorithms [J]. Computers Chem. Engng. 1998, 22(S): 805 - 808

#### 本文作者简介

徐智 1974年生,1995年毕业于哈尔滨船舶工程学院自动控

制系,1998年获哈尔滨工程大学自动控制系硕士学位,现为上海交通大学控制理论与控制工程专业博士生,研究方向为混合生产调度等。

席裕庚 见本刊 2001 年第 2 期第 170 页

韩兵 1958年生,1987和1993年毕业于西北大学航天工程系,分别获硕士和博士学位,现为上海交通大学自动化所副教授,研究方向为控制系统故障诊断与容错控制,计算机集成制造系统,生产过程调度,发表论文 20 余篇。