

文章编号: 1000-582x(2000)06-0053-03

## 基于粗糙集理论的人工神经网络故障诊断系统

孙颖楷<sup>1</sup>, 张邦礼<sup>1</sup>, 曹龙汉<sup>2</sup>, 曹长修<sup>1</sup>

(1 重庆大学自动化学院, 重庆 400044; 2. 重庆通信学院电源技术系, 重庆 400035)

**摘要:** 在故障诊断神经网络模型的基础上, 以粗糙集理论中的信息系统属性值表为主要工具, 将复杂的神经网络分层约简并剔除其中不必要的属性, 克服了网络规模过于庞大及分类识别速度慢等缺点, 取得了减少分类过程中的模式匹配搜索量的良好效果, 并给出基于粗糙集理论的分层发掘神经网络模型结构及算法, 结果表明该系统对工程应用具有一定的参考价值。

**关键词:** 故障诊断; 粗糙集; 约简; 数据发掘; 人工神经网络

**中图分类号:** TP 182; TP 183

**文献标识码:** A

T827

神经网络在机器学习、容错能力、并行推理能力以及可以任意逼近一非线性函数的能力等方面具有突出的优越性, 而这些方面恰好是传统专家系统的主要弱点, 因此将其用于故障诊断有着广阔的应用前景。由于诊断问题的实质是一种映射, 是将故障的征兆与故障之间的对应关系看作是一个映射, 从而可用一种前馈型网络来逼近这种映射关系, 实现对故障进行分类。但是在对复杂系统进行诊断时, 往往由于网络规模过于庞大和学习训练时间超长等问题, 降低了系统的实用性。而粗糙集理论能有效地分析和处理不精确、不完整、不一致等不完备性数据, 可以发现数据间隐藏的关系, 提取有用信息, 简化信息处理, 已在图象处理、模式识别、数据挖掘等众多领域获得成功的应用<sup>[1]</sup>。

笔者以粗糙集理论为主要工具, 结合知识的泛化、特化等概念, 将分类对象由高层次的普遍模式向低层次的具体模式逐层分类, 减少了分类中的模式匹配搜索量, 有效地解决了分类空间的组合爆炸问题。

## 1 粗糙集理论<sup>[2~4]</sup>

粗糙集理论的主要思想是在保持分类能力不变的前提下, 通过对知识的约简, 导出概念的分类规则。其

中知识被认为是一种对抽象或现实的对象进行分类的能力, 根据所讨论对象的特征差别, 将其分门别类的能力均可以看作是某种知识。分类过程中相差不大的个体被归于一类, 它们的关系就是不可分辨关系, 也称等价关系。

### 1.1 知识的等价、特化、泛化

不可分辨关系是粗糙集理论的基石, 揭示了论域中知识的颗粒结构, 也是定义其他概念的基础, 为此首先给出不可分辨关系的定义。

**定义 1** 给定一有限的非空集合论域  $U$ , 定义  $R$  代表论域  $U$  中的一种等价关系, 则称  $U$  上的分类族, 即知识库  $K = (U, R)$ , 为一个近似空间。

**定义 2** 对于子集  $X, Y \subset U$ , 若根据关系  $R$ ,  $X$  和  $Y$  的属性不可分辨时, 用  $[X]_R$  来表示, 它代表子集  $X$  和  $Y$  同属  $R$  中的一个范畴。

**定义 3** 若  $P \subset R$ , 且  $P \neq \Phi$ , 则  $P$  中全部等价关系的交集也是一种等价关系, 称为  $P$  上的不可分辨关系, 记为  $\text{ind}(P)$

$$[X]_{\text{ind}(P)} = \bigcap [X]_R \quad P \subset R$$

在不可分辨关系的基础上, 下面引入 RS 理论中关于知识的等价、特化以及泛化等概念的定义:

**定义 4** 令  $P, Q \subset R$ ,  $P, Q$  都是关于论域上的

· 收稿日期: 2000-04-24

基金项目: 总参军训部国防预研基金、国家高等学校博士学科点专项基金(98061117)

作者简介: 孙颖楷(1973-), 男, 江苏无锡人, 重庆大学博士生, 主要从事粗糙集理论、故障诊断、信号处理等领域的研究。

知识,且  $K = (U, P)$  和  $K_1 = (U, Q)$  为两个知识库,当  $\text{ind}(P) = \text{ind}(Q)$  时,称知识库  $K, K_1$  是等价的。

这个概念意味着可以用不同的属性集对同一对象进行描述,以表达关于论域上完全相同的事实,即  $K$  与  $K_1$  具有相同的表达能力。

**定义 5** 对于知识库  $K = (U, P)$  和  $K_1 = (U, Q)$ ,当  $\text{ind}(P) = \text{ind}(Q)$  时,称  $P(K)$  知识比  $Q(K_1)$  知识更精细、或者说  $Q$  比  $P$  粗糙。同时,当  $P$  小于  $Q$  时,称  $P$  为  $Q$  的特化, $Q$  为  $P$  的泛化。

## 1.2 知识表示系统

**定义 1** 设  $U$  为论域, $P, Q$  是  $U$  上的两个等价关系族,且  $Q \subseteq P$ ,如果满足,1)  $\text{ind}(Q) = \text{ind}(P)$ ;2)  $Q$  是独立的,则称  $Q$  是  $P$  的一个约简。

**定义 2** 设  $U$  为论域, $P$  是定义在  $U$  上的  $n$  等价关系族, $P$  中所有必要关系组成的集合,称为关系族  $P$  的核,记作  $\text{core}(P)$ 。

**定义 3** 称  $DS = (U, A, V, f)$  为知识表示系统,

式中: $U$  为关于对象的非空有限集,称为论域; $A$  为对象属性的集合,且  $A = C \cup D$ ,即属性集合由条件属性集和决策属性集构成, $C, D$  满足  $C \cup D = A, C \cap D = \emptyset$ ;  $V$  为属性值的集合; $f: U \times A \rightarrow V$  为一单射,指定  $U$  中每一对象  $x$  的属性值。

根据知识表示系统的定义,即可很方便地用一个二维表格来表达,这种数据表被称为知识表示系统(KRS)在这张表中,列表示属性,行表示实例,这样知识的化简即可转化为属性的约简。

## 2 分层发掘粗集网络模型及算法

对于所讨论的对象,可认为是由有限个部件按一定规律组合而成的系统,如将构成系统的部件称为元素  $E$ ,而元素间的连接称为联系  $L$ ,则系统构成可抽象定义为  $S = (E, L)$

对于复杂系统,可进一步进行分解,即高层元素可分解为低层元素集合,如用子系统表示系统层次元素,则系统结构的层次特性可表示为

$$S_k^i = \{S_k^{i+1}\} \quad k = 1, 2, \dots, m$$

其中,  $S_k^i$  表示系统第  $k$  层上的第  $i$  个子系统。

因此,系统结构的层次性决定了系统故障的层次性。系统产生故障的原因可能是构成该系统的元素发

生故障,即故障的传播是一个由低层向高层的逐层传播过程。

将层次分类模型看作是一棵概念层次树,则可知每一个概念节点只有一个父节点,但可以有若干个子节点。一个节点的父节点所表示的概念即是该节点所表示概念的泛化;同理,一个节点的子节点所表示的概念即是该节点所表示概念的特化。这样就可以利用粗糙集理论来降低系统诊断问题的复杂性。

由于前馈型神经网络是众多神经网络模型中应用最为广泛的网络之一,且具有较强的模式分类能力,在实现从  $R^n$  到  $R^m$  映射的同时能获得满意的收敛精度,应是较理想的诊断模型,由于常规 BP 算法存在收敛速度慢和可能会陷入局部极小点等问题,因此选取附加动量项的三层前向 BP 网络来作为系统的诊断模型。

在选定了神经网络的结构后,即可进行系统的诊断工作,下面给出基于粗糙集理论的分层诊断算法:

1) 对故障标准样本集中的连续属性值利用聚类方法进行离散化,得到粗糙集理论所需的 KRS 表;

2) 对整个系统进行分解,建立合适的分类层次模型;

3) 首先在模型的较高概念层次进行发掘,将原始数据级上的概念提升到本层进行泛化,再利用 RS 理论进行属性值的约简,剔除多余的属性;

4) 根据约简后的属性,建立相应的神经网络并采用合适的算法进行网络的学习训练,完成系统故障的粗诊子网络;

5) 根据诊断要求,可对相应的低层子系统进行进一步的概念特化,即逐步向更低的层次进行发掘,同样利用 RS 理论进行属性值约简,建立相应的子神经网络,并对网络进行学习训练后完成故障的细诊子网络;

6) 逐步细化,当发掘到系统的原始数据级上时,停止发掘,完成整个分层诊断网络模型的建立。

## 3 分层发掘网络模型的应用

内燃机作为动力机械,其运行状态的好坏,直接影响到成套设备的工作状况。因此对其进行运行状态监测和故障诊断,确保设备处于最佳运行状态,有着极大的社会、经济效益。本文仅以此故障诊断系统为例,说明基于粗糙集理论的分层发掘网络模型的建立过程。首先对该系统的故障标准样本谱中征兆的连续属性值

利用 SOFM 方法进行离散化预处理,可得表 1 所示 KRS 数据表。

由于该系统较为简单,假定故障类型的概念层次树共 3 层,则故障树如图 1 所示。

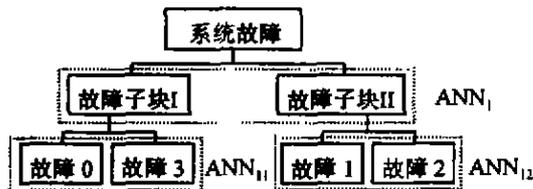


图 1 系统的故障树

表 1 故障标准样本谱的 KRS 数据表

	征兆 a	征兆 b	征兆 c	征兆 d	故障类型
1	0	1	1	1	0
2	0	0	0	0	0
3	0	0	1	1	1
4	0	0	1	0	1
5	0	1	1	2	3
6	0	1	2	2	3
7	1	2	1	2	2
8	0	1	1	0	2
9	0	1	2	1	2
10	1	2	2	2	2

首先将发掘层次定为故障子块层,则将相应子节点的概念提升到故障子块层,即进行概念的泛化,得到如表 2 所示的 KRS 数据表。

针对表 2,采用粗糙集理论进行属性的约简,可知在对系统进行故障的粗诊时,征兆 a 是多余的,即只需征兆 b、征兆 c、征兆 d 就可以初步判断故障是属于故障子块 I 还是子块 II。因此本层的神经网络 ANN<sub>1</sub> 只需征兆 b、c、d 这 3 个输入参数、1 个神经元输出诊断结果。

如需进一步发掘故障的类型,则对故障子块 I 进行概念特化,如表 3 所示,然后利用 RS 理论对该子节点层进行属性的约简,可知对属于范畴为子块 I 的故障进一步确定其类型时,只需属性 d 即可判断系统故障是属于故障 0 还是故障 3,则子神经网络 ANN<sub>11</sub> 的结构为 1 输入、1 输出;同理,对属于范畴为子块 II 的

故障而言,进一步确定其类型时,属性 a、c 是多余的,即 ANN<sub>12</sub> 的结构为 2 输入、1 输出。

表 2 概念提升后的 KRS 数据表

	征兆 a	征兆 b	征兆 c	征兆 d	故障子块
1	0	1	1	1	I
2	0	0	0	0	I
3	0	0	1	1	II
4	0	0	1	0	II
5	0	1	1	2	I
6	0	1	2	2	I
7	1	2	1	2	II
8	0	1	1	0	II
9	0	1	2	1	II
10	1	2	2	2	II

表 3 故障子块 I 概念特化后的 KRS 数据表

	征兆 b	征兆 c	征兆 d	故障类型
1	1	1	1	0
2	0	0	0	0
5	1	1	2	3
6	1	2	2	3

#### 4 结束语

本文在故障诊断神经网络模型的基础上,引入在数据发掘方面日益受到重视的粗糙集理论,并以信息系统属性值表为主要工具,将复杂的神经网络分层约简并剔除不必要的属性,解决了原网络规模过于庞大、分类识别速度慢等问题,在实际应用中令故障由高层向低层逐层发掘,减少了分类中的模式匹配搜索量,实践证明本系统具有较高的实用价值。

#### 参考文献:

- [1] PAWLAK Z Rough Sets[J]. Communication of the ACM, 1995,38(11):89-95.
- [2] 苗夺谦,王珏.粗糙集理论中概念与运算的信息表示[J]. 软件学报,1999,10(2):113-116.
- [3] 李永敏,朱善君,陈湘晖等.基于粗糙集理论的数据挖掘模型[J]. 清华大学学报,1999,39(1):110-113.
- [4] 曾黄麟.粗集理论及其应用[M]. 重庆:重庆大学出版社, 1996.

(下转 86 页)

