

基于模型诊断的改进贝叶斯方法

贾学婷 欧阳丹彤 张立明

(吉林大学计算机科学与技术学院 长春 130012)

(吉林大学符号计算与知识工程教育部重点实验室 长春 130012)

摘 要 基于模型诊断是针对系统或设备的行为和结构建立模型,从而进行诊断的。但是基于模型诊断的方法存在不确定性问题,诊断的结果可能为一组故障部件。为解决不确定性问题,很多学者在基于模型诊断中使用了概率的方法,利用待诊断设备组成部件的故障概率信息来寻找最可能的诊断。通过对模型诊断中存在的确定性问题的深入研究,在基于模型诊断中提出了概率的贝叶斯解释,从而利用后验概率形式量化了元件故障的可能性的衡量标准,并且改进了计算元件后验概率的方法,分析了改进后算法的复杂性和完备性,证明了改进后的方法降低了时间和空间的复杂性。实验结果表明,改进后算法的执行效率较原有的算法有明显的提高,且有些问题可以提高两个数量级。

关键词 基于模型诊断,贝叶斯理论,一致性诊断

中图法分类号 TP306

文献标识码 A

Improved Bayesian Method for Model-based Diagnosis

JIA Xue-ting OUYANG Dan-tong ZHANG Li-ming

(School of Computer Science and Technology, Jilin University, Changchun 130012, China)

(Key Laboratory of Symbolic Computation and Knowledge Engineering of Ministry of Education, Jilin University, Changchun 130012, China)

Abstract Model-based diagnosis concerns using a model of the structure and behavior of a system or device in order to establish why the system or device is faulty. But the fact is that determining a diagnosis for a problem always involves uncertainty. This situation is not entirely satisfactory. This paper built upon and extended previous work in model-based diagnosis by supplementing the model-based framework with probabilistic sound ways for dealing with uncertainty. This was done in a mathematically way in Bayesian theory to compute the posterior probability that a certain component is not working correctly given some diagnosis. And in this paper we proposed a general method to increase efficiency. The complexity and the completeness of the method were analyzed. The time complexity and the space complexity were reduced in the improved method. The experimental results illustrate that the improved method has a better executive efficiency than the traditional method in general. In fact, the executive efficiency may be improved up to two orders of magnitude in some cases.

Keywords Model-based diagnosis, Bayesian theory, Consistency-based diagnosis

1 引言

基于模型诊断是 20 世纪 70 年代兴起的一项智能推理技术,它对于人工智能领域内的研究具有重大意义。

基于模型诊断的基本思想^[1-3]是,用系统的内部结构和行为的知识对系统进行诊断。如果预测到的行为与实际观测得到的信息不相符合,则说明系统存在故障,可利用模型进行推理,找出故障部件。

基于一致性诊断是模型诊断的一个重要方法,它利用正常工作的设备的结构和行为知识来推断出系统的故障元件。

基于一致性诊断是一种基于假设的诊断方法,首先假设某个诊断结果,随后只要在接下来的推理过程中没有得到反

驳,那么该诊断结果的假设便成立。但是这种诊断方式也为诊断引入了不确定性,因为无法明确地量化不确定性,只能假设所有诊断结果存在的可能性都是相等的。但在真实条件下,这种情况十分罕见。

对于诊断领域内的不确定性问题,比较好的解决方式是将概率模型引入到模型诊断的逻辑框架之内,许多学者进行了这一方面的研究。以下回顾了以往学者们的几种研究工作,并进行了总结和比较分析。

De Kleer 和 Williams^[5,6]首先将概率的方法引入到基于模型诊断之中,并加入信息理论的方法,可将较大的诊断空间进一步缩小。但是该方法的缺点是计算之前需要得到候选的观测变量的条件分布,可实际上候选的规模通常很大,无法归

到稿日期:2009-09-16 返修日期:2009-12-07 本文受国家自然科学基金重大项目基金(60496320,60496321),国家自然科学基金(60973089,60773097,60873148),新世纪优秀人才支持计划项目基金,吉林省科技发展计划项目基金(20080107,20060532)资助。

贾学婷(1983—),女,硕士生,主要研究方向为基于模型诊断,E-mail:jxt1325@yahoo.com.cn;欧阳丹彤(1968—),女,教授,博士生导师,主要研究方向为基于模型诊断和定理机器证明;张立明(1980—),男,博士生,主要研究方向为基于模型诊断。

纳出一个合理的概率分布。

另一种处理不确定性问题的方法是贝叶斯网方法。Pearl^[17]利用贝叶斯网来模型化诊断问题,并用概率进行计算。但是该方法也有一定的缺陷: Pearl 假定了元件输出的条件概率分布是均等的,然而这样的假设过于苛刻。

Kohlas 等人^[9,11,12]提出了另一种计算系统元件故障的后验概率的方法(以下简称 Kohlas 方法)。该方法将系统部件状态集分为与观测一致的集合和与观测不一致的集合,这与基于一致性诊断的思想是相似的。随后再利用贝叶斯公式进行故障定位,计算出每个元件故障的可能性。与 De Kleer 的方法相比,该方法有一定的优点,例如它并不需要针对观测归纳其概率分布,并且可以计算出诊断中每个元件故障的可能性,因而具有更高的实用性。且与 Pearl 的方法相比,该方法在计算元件的后验概率时只需要已知元件的先验概率,并且故障元件对系统带来的影响由系统的逻辑描述来说明,因而其更准确、清晰。但是这种方法的缺点是当系统的诊断数量较多或部件较多时,其计算量是很大的。本文主要对 Kohlas 方法进行改进,在不需要已知最小冲突集的条件下,降低原方法的计算复杂性,并且通过运用实例,验证了优化方法的有效性和简便性。

本文第 1 节是对以往关于不确定性问题研究的回顾;第 2 节简要介绍基于模型诊断的相关概念;第 3 节阐述了基于模型诊断的贝叶斯解释;第 4 节对 Kohlas 等人提出的计算元件后验概率的方法进行优化改进;第 5 节给出用本文改进的方法求解的一个实例,对算法完成了程序实现,并进行了分析;最后对本文提出的方法进行总结。

下面对本文所用到的相关知识进行简要介绍。

2 相关知识

首先对与模型诊断有关的概念进行定义。

定义 1^[2] 系统定义一个三元组 $(SD, COMPS, OBS)$, 其中 SD 为系统描述, 是一阶谓词公式的集合; $COMPS$ 是系统的组成部件集合, 是一个有限的常量集; OBS 是系统的一个观测集, 是一阶谓词公式的有限集合。

定义 2^[2] 设 $\Delta \subseteq COMPS$, 如果 $SD \cup OBS \cup \{AB(c) | c \in \Delta\} \cup \{\neg AB(c) | c \in COMPS - \Delta\}$ 是一致的, 那么 Δ 就是关于 $(SD, COMPS, OBS)$ 的基于一致性诊断。

基于一致性诊断 Δ 是基于一致性极小诊断, 当且仅当 Δ 的任一真子集 Δ' 均不是一个基于一致性的诊断。

3 Kohlas 等人基于模型诊断的贝叶斯解释

基于模型诊断方法最后得出的诊断是一组引发故障的元件集合, 并不能精确定位故障部件。但是在实际应用中, 得到单个元件故障的可能性是十分重要的。因而考虑将贝叶斯概率理论引入基于模型诊断之中, 用后验概率定量地表示部件故障的可能性, 使得诊断更清晰精确。

3.1 Kohlas 等人计算后验概率方法的基本思想

Kohlas 等人提出一种通用的诊断方法, 用来辅助鉴定故障部件。该方法以基于逻辑的方法为基础, 通过在 Reiter^[2]的逻辑框架内引入概率思想, 扩展了基于模型诊断的思想。

在给出 Kohlas 等人计算后验概率方法的基本思想前, 先对相关的定义进行如下说明。

定义 3^[9] (系统状态) 假设系统有 n 个元件, 系统的元件集合为 $c = \{c_1, c_2, \dots, c_n\}$ 。在对系统进行任何观测之前, 对系统中的每一个元件来说, 都有一个先验概率值, 可以是元件在出厂时标定的故障概率等。为每一个元件 c_i 添加一个与其对应的布尔变量 x_i , 当元件 c_i 工作正常时, 布尔向量 $x_i = 1$; 当元件 c_i 工作不正常时, 布尔向量 $x_i = 0$ 。我们把处于 $\{0, 1\}^n$ 中的布尔向量 $x = (x_1, x_2, \dots, x_n)$ 称为系统状态。

定义 4^[9] (系统状态的先验概率) 用 p_i 表示元件 c_i 正常工作的先验概率, 在未对系统做任何观测时, 某一系统状态 $x = (x_1, x_2, \dots, x_n)$ 是可能存在的系统状态的先验概率为:

$$p(x) = \prod_{i=1}^n p_i^{x_i} (1 - p_i)^{(1-x_i)} \quad (1)$$

Kohlas 方法的基本思想是, 按照基于逻辑的一致性推理方法将系统部件状态集分为可能的系统状态集和不可能的系统状态集。

在对系统进行观测之前, 系统有 2^n 个系统状态。但当对系统进行观测并获得一次测量结果时, 与观测相一致的系统状态称为可能的系统状态, 假设系统可能的状态集合为 N_d , 某一个系统状态 $x \in N_d$, 则意味着该系统状态 x 是对观测的一个可能的解释, 也就是说该系统状态实际上就等于系统的一个可能的诊断; 而与观测不一致的状态集合为 N_c , 可视为一个冲突集。集合 N_d 和集合 N_c 是具有互补关系的两个集合。

3.2 Kohlas 等人计算后验概率的方法

在对系统进行观测后, 得到的不可能的状态集合 N_c 中的系统状态的后验概率可调整为 0; 可能的系统状态集合 N_d 中的系统状态的后验概率, 可利用贝叶斯定理, 由式(1)中确定的系统状态先验概率调整为与集合 N_d 相符合的后验概率。

定理 1^[9] 观测后系统状态的后验概率为:

$$P'(x) = \begin{cases} \frac{p(x)}{p(N_d)}, & \text{if } x \in N_d \\ 0, & \text{if } x \in N_c \end{cases} \quad (2)$$

定理 1 中的 $p(N_d)$ 表示集合 N_d 中的系统状态的先验概率的加和。可以看出, 定理 1 中的概率 $P'(x)$ 即为给出观测后的系统状态的后验概率。

据此可以求出单个元件故障的后验概率。假设 N_i 表示所有 $x_i = 0$ 的系统状态的集合, 也即所有包含元件 c_i 为故障的系统状态的集合, 则某个元件 c_i 故障的后验概率如定理 2。

定理 2^[9]

$$P'(N_i) = p(N_i | N_d) = \frac{p(N_i \cap N_d)}{p(N_d)} = \sum_{x \in N_i \cap N_d} P'(x) \quad (3)$$

可以看到, 这种方法的关键是找到集合 N_d , 即系统的极小诊断。在此, 我们通过逻辑方法得到诊断, 仅对诊断结果进行计算和分析, 但是这种方法的计算量仍然过大。

Kohlas 等人利用极小冲突集简化了计算, 但是这就使得该方法只能运用在利用极小冲突集求解的诊断之中。

3.3 Kohlas 等人计算后验概率方法的计算复杂性

Kohlas 等人计算后验概率方法的时间复杂度及空间复杂度主要与元件个数和极小诊断个数相关, 最坏的情况下其复杂度为 $O(mn^2)$, 其中 n 表示系统的部件个数, m 为系统的极小诊断个数。

当系统的部件数较大、诊断的个数较多时, 原方法的计算

量过大。本文提出了一种新的优化方法,该方法不需要知道极小冲突集即可降低确定元件后验概率的计算量。两种方法的计算复杂度将在第 4.3 节中进行比较分析。

4 改进的后验概率计算方法

4.1 改进的后验概率计算方法的基本思想

针对原方法计算量过大的问题,对 Kohlas 等人计算后验概率的方法进行改进,将原方法求系统状态后验概率的式(2)进行简化,在保证原方法准确性以及通用性的前提下,降低计算量。

首先提出如下几个定义。

定义 5 假设在对系统加入观测之前,每个系统元件 c_i 正常工作的先验概率为 p_i ,定义 d_i 为第 i 个元件的故障概率与正常概率比值:

$$d_i = \frac{1-p_i}{p_i} \quad (4)$$

定义 6 假设系统状态 $C_k = (1, 1, \dots, 1)$, 表示系统中所有的元件均正常,根据系统状态的先验概率的定义即式(1),定义该系统状态 C_k 的先验概率为:

$$p(C_k) = \prod_{i=1}^n p_i \quad (5)$$

定义 7 改写先验概率公式。利用式(4)、式(5)将系统状态的先验概率(定义 4)改写为以下的形式:

$$P(x) = \prod_{i=1}^n p_i^{x_i} (1-p_i)^{(1-x_i)} = \prod_{i=1}^n p(C_k) d_i^{(1-x_i)} = p(C_k) \prod_{i=1}^n d_i^{(1-x_i)} \quad (6)$$

改进的后验概率计算方法的基本思想是:首先仍然通过基于逻辑的推理方法将系统部件状态集分为可能的系统状态集和不可能的系统状态集。不可能的系统状态将被排除不用,不再需要进行改进。

而对于求解可能的系统状态的后验概率,可以通过引入单个元件的故障与正常的先验概率比值(定义 5)和元件全部正常的系统状态的概率(定义 6),通过数学的方法进行化简,从而在很大程度上简化了利用贝叶斯定理求解元件后验概率的计算复杂度。

4.2 改进的计算元件后验概率的方法

以下是新方法求解观测后系统中单个元件的后验概率的方法。

定理 3 集合 N_i 表示所有的 $x_i = 0$ 的系统状态的集合,也即所有第 i 个元件故障的系统状态集合,则元件故障的后验概率为:

$$SP'(N_i) = p(N_i | N_d) = \frac{\sum_{x \in N_i \cap N_d} \prod_{i=1}^n d_i^{(1-x_i)}}{\sum_{x \in N_d} \prod_{i=1}^n d_i^{(1-x_i)}} \quad (7)$$

证明:在定理 3 中,新方法计算元件的后验概率的公式为:

$$SP'(N_i) = \frac{\sum_{x \in N_i \cap N_d} \prod_{i=1}^n d_i^{(1-x_i)}}{\sum_{x \in N_d} \prod_{i=1}^n d_i^{(1-x_i)}}$$

我们需要证明,Kohlas 方法中计算元件后验概率的公式与其等价。

按照 Kohlas 方法计算观测发生之后的元件的后验概率为:

$$P'(N_i) = p(N_i | N_d) = \frac{p(N_i \cap N_d)}{p(N_d)} = \frac{\sum_{x \in N_i \cap N_d} p(x)}{\sum_{x \in N_d} p(x)} = \frac{\sum_{x \in N_i \cap N_d} p(C_k) \prod_{i=1}^n d_i^{(1-x_i)}}{\sum_{x \in N_d} p(C_k) \prod_{i=1}^n d_i^{(1-x_i)}} \quad (8)$$

由定义 6 可知,系统状态 $C_k = (1, 1, \dots, 1)$ 表示系统中所有的元件均正常工作,该系统状态的先验概率为 $p(C_k) = \prod_{i=1}^n p_i$, 所以对于每个系统来说 $p(C_k)$ 都可以视为一个常量,因此式(8)中的 $p(C_k)$ 可以约分。

约分后的最后结果为:

$$P'(N_i) = \frac{\sum_{x \in N_i \cap N_d} \prod_{i=1}^n d_i^{(1-x_i)}}{\sum_{x \in N_d} \prod_{i=1}^n d_i^{(1-x_i)}} \quad (9)$$

由此可以看出,求元件后验概率的新方法与 Kohlas 等人的计算元件后验概率方法等价。

4.3 改进后方法的计算复杂性

完备性分析:改进后的方法仍然建立在以逻辑方法得到的诊断结果的基础之上,通过引入合理的定义,利用数学的方法来简化原方法,并且可以证明两种方法的等价性,因而改进的计算后验概率的方法是完备的。

复杂性分析:改进后计算后验概率方法的时间复杂度及空间复杂度主要与元件个数相关,最坏情况下其复杂度为 $O(n^2)$, 其中 n 为系统中的元件个数。

原方法的复杂度为 $O(mn^2)$, 其中 n 为系统中的元件个数, m 为利用逻辑方法得出的系统的极小诊断的个数。由此可以看出,改进后方法的优越性是显而易见的。原方法的计算复杂度不但与系统的元件个数相关,而且与系统的极小诊断个数相关。而改进后方法的复杂度只与系统的元件个数有关,这就在很大程度上降低了计算复杂度。

下面用一个实例来验证改进方法的优越性。

5 实例分析

图 1 为一个有 5 个元件的 poly-box 系统,系统部件集合 $COMPS = \{m_1, m_2, m_3, a_1, a_2\}$, 其中 SD 是系统描述; $COMPS$ 是系统的组成部件集合; OBS 为一个观测集,是用一阶谓词公式的有限集对一个系统的一次测量的描述。




图 1 5个元件的 poly-box 系统

图 1 的故障电路由 3 个乘法器 m_1, m_2, m_3 和两个加法器 a_1, a_2 组成。在该电路中,系统描述为正常输入、输出行为以及拓扑连接关系等。例如 $out(m_1) = mul(in_1, in_2)$, 表示乘法器 m_1 的输出是输入 in_1 和 in_2 的相乘。

本电路一次测量 OBS 为:

$$\begin{aligned} in_1(m_1) &= 3 & in_2(m_1) &= 2 \\ in_1(m_2) &= 3 & in_2(m_2) &= 2 \\ in_2(m_3) &= 2 & out(a_1) &= 10 \end{aligned}$$

由观测可知系统发生单故障输出,由基于模型诊断的逻辑方法可以得出系统的 4 个极小诊断:

$$\{m_1\}, \{a_1\}, \{m_2, m_3\}, \{m_2, a_3\}$$

由于基于模型的诊断最终给出的是一组引发故障的元件集合,因此用贝叶斯后验概率的方法,利用诊断集合可以确定每个元件发生故障的可能性。

首先建立一个基于模型诊断的贝叶斯模型。假设图 1 所示的系统由一个元件集合 $c = \{c_1, c_2, \dots, c_n\}$ 组成,其中 m_1, m_2, m_3, a_1, a_2 分别用 c_1, c_2, c_3, c_4, c_5 表示。

在对系统的状态做任何观测之前,元件 c_i 正常的先验概率为 p_i 。

在图 1 的系统中,假设每个元件都正常的先验概率为 $p_1 = p_2 = p_3 = 0.95, p_4 = p_5 = 0.99$ 。

那么首先按照 Kohlas 方法,由定义 4 和定理 1 可计算出系统中每个元件故障的概率:

$$P(m_1) = 0.797 \quad P(m_2) = 0.05 \quad P(m_3) = 0.042$$

$$P(a_1) = 0.153 \quad P(a_2) = 0.008$$

现在按照改进后的方法再次进行计算。首先计算出第 i 个元件的故障概率与正常概率的比值,分别为:

$$d_1 = \frac{1-p_1}{p_1} = 0.05$$

$$d_2 = 0.05$$

$$d_3 = 0.05$$

$$d_4 = 0.01$$

$$d_5 = 0.01$$

由定理 3 可以简便地计算出每个元件的故障概率:

$$P(m_1) = 0.797 \quad P(m_2) = 0.05 \quad P(m_3) = 0.042$$

$$P(a_1) = 0.153 \quad P(a_2) = 0.008$$

由此可以看到,改进前后两种方法计算得到的元件故障概率相同。从实验的角度可以看出两种方法的计算结果相同,改进后的方法是准确的。

图 2 是利用贝叶斯方法计算系统元件后验概率的程序运行图,图 3 是改进前方法和改进后方法的程序实现的运行时间线图,表 1 是分别利用改进前后的贝叶斯方法计算系统元件故障概率的实验时间。




图 2 5 个元件的 playbox 系统的程序运行界面




图 3 改进前后两种方法的程序运行时间线图

表 1 利用改进前后的贝叶斯方法计算 poly-box 系统元件后验概率的时间表

系统元件的个数	Kohlas 方法的计算时间(ns)	改进后方法的计算时间(ns)
5	623823	211759
9	10316396	988671
14	15672662	2344991
20	23478956	3159654

实验利用改进前后的方法,分别对五元件电路系统、九元件系统、十四元件系统以及二十元件系统的情况进行计算。算法在 JAVA6 环境下实现 (AMD Athlon 64X2 Dual 2.1GHz, 2G 内存, 中文 WindowsXP)。

在图 3 中,折线 B 表示的是原方法计算 4 个系统中各个元件的后验概率所需要的时间,折线 A 表示的是利用改进后的方法计算 4 个系统中各个元件的后验概率所需要的时间。从该图中可以直观地看到,改进后算法的执行效率较原方法有了显著提高。结合表 1 可以看出,改进后的方法在计算时间上平均减少了 6/7 左右;在计算九元件电路系统时,运算时间甚至减少了近两个数量级。

从实验结果中可以看出,在试验的 4 个系统中,利用改进后的方法计算得到的各个元件的后验故障概率与利用原方法计算得到结果相同,但是运算时间明显缩短,在很大程度上降低了原方法的计算量。

结束语 综上所述,本文改进了 Kohlas 等人计算系统元件后验概率的方法,并给出了不同元件电路诊断的实际例子。改进后的方法能够在数值上直观地反映元件发生故障的可能性,并且大大降低了原方法的计算复杂度;无需利用极小冲突集便可进行计算,这又增大了计算后验概率方法的通用性。改进后的方法可以针对任何逻辑上得出的诊断结果进行计算。

但是本方法仍有一些不足之处。例如,利用本方法进行计算时,假设了各个元件之间相互独立,但是在实际情况下,有很多时候这种假设都过于严格。而贝叶斯网络是一种能够表示因果逻辑的概率网络,是贝叶斯定理的延伸。本文的后续工作将考虑利用贝叶斯网络来表示元件之间的相互关系,以此来更加准确深入地解决不确定性问题。

参考文献

- [1] De Kleer J, Kurien J. Fundamentals of model - based diagnosis [C]//Staroswiecki M, Wu N E, eds. Proceedings of the 5th IF-AC Symposium on Fault Detection, Supervision, and Safety of Technical Processes. Washington, D. C., USA; Elsevier, 2003: 25-36
- [2] Reiter R. A theory of diagnosis from first principles [J]. Artificial Intelligence, 1987, 32(1): 57-96
- [3] De Kleer J, Mackworth A K, Reiter R. Characterizing Diagnoses and Systems [J]. Artificial Intelligence, 1992, 56(2/3): 197-222
- [4] Davis R. Diagnostic reasoning based on structure and behavior [J]. Artificial Intelligence, 1984, 24(1-3): 347-410
- [5] De Kleer J, Williams B C. Diagnosis multiple faults [J]. Artificial Intelligence, 1987, 32(1): 97-130
- [6] De Kleer J. Using crude probability estimates to guide diagnosis [J]. Artificial Intelligence, 1990, 45(3): 381-392

间进行全局最优搜索,实现泛函网络结构和泛函参数的共同学习,有效提高了泛函网络的收敛精度,并可获得更为简洁的网络结构。

参 考 文 献

- [1] Castillo E. Functional Networks[J]. Neural Processing Letters, 1998,7:151-159
- [2] Castillo E, Cobo A, Gutierrez J M. Functional Networks with Applications[M]. Kluwer Academic Publishers, 1999
- [3] Castillo E, Hadi Ai S, Locruz B. Semi-parametric Nonlinear Regression and Transforming Using Functional Networks[J]. Computational Statistics & Data Analysis, 2008, 52: 2129-2157
- [4] Castillo E, Gutierrez J M, Cobo A, et al. A minimax method for learning functional networks[J]. Neural Processing Letters, 2000, 11(1): 39-49
- [5] Castillo E, Cobo A, Gutiérrez J M, et al. Functional networks with applications[M]. Kluwer Academic Publishers, 1999
- [6] Iglesias A, Arcay B, Cotos J M, et al. A comparison between functional networks and artificial neural networks for the prediction of fishing catches[J]. Neural computer & applied, 2004, 13: 24-31
- [7] Fontenla-Romero O, Castillo E, Alonso-Betanzos A. A Measure of Fault Tolerance for Functional Networks[J]. Neurocomputing, 2004, 62: 327-347
- [8] Zhou Yongquan, Jiao Licheng. Interpolation Mechanism of Functional Networks[J]. Lecture Notes in Computer Science, 2005, 369: 45-51
- [9] Zhou Yongquan, Jiao Licheng. Approximate Factorization Learning Algorithm of Multivariate Polynomials Based on Functional

Networks[J]. Journal of Information and Computational Science, 2005, 2(1): 205-210

- [10] Zhou Yongquan, He Dexu, Jiao Licheng. A Neural Computation Structure for Solving Functional Equations with Functional Networks[J]. Journal of Information and Computational Science, 2005, 2(4): 835-842
- [11] He Dexu, Nong Zheng, Zhou Yongquan. Approximate Factorization of Univariate Polynomials Using Functional Networks[J]. Journal of Information and Computational Science, 2005, 2(3): 473-479
- [12] Zhou Yongquan, Jiao Licheng. One-variable interpolation function based on functional networks[J]. International Journal of Information Technology, 2006, 12(2): 120-129
- [13] 周永权, 焦李成. 层次泛函网络整体学习算法[J]. 计算机学报, 2005, 28(8): 1277-1286
- [14] 周永权, 赵斌, 焦李成. 一种复值泛函网络逼近理论及学习算法[J]. 系统工程与电子技术, 2006, 28(8): 1244-1248
- [15] 周永权, 焦李成. 基于泛函网络的多维函数逼近理论及学习算法[J]. 系统工程与电子技术, 2005, 27(5): 906-909
- [16] 周永权, 赵斌, 焦李成. 序列泛函网络模型及其学习算法与应用[J]. 计算机学报, 2008, 31(7): 1073-1081
- [17] 周永权, 吕咏梅, 申芸. 正交泛函网络函数逼近理论及算法[J]. 计算机科学, 2009, 36(1): 138-141
- [18] 周永权, 刘晓冀, 张明. 基于多项式基函数的泛函网络构造方法与逼近理论[J]. 计算机科学, 2008, 35(08): 119-122
- [19] 张铃, 张钊. 遗传算法机理的研究[J]. 软件学报, 2000, 11(7): 945-952
- [20] 云庆夏. 进化算法[M]. 北京: 冶金工业出版社, 2000

(上接第 194 页)

- [7] De Kleer J. Focusing on probable diagnoses[C]//Proc. 9th National Conference on Artificial Intelligence, 1991: 842-848
- [8] Poole D. A logical framework for default reasoning[J]. Artificial Intelligence, 1988, 36(1): 27-47
- [9] Kohlas J, Monney P A, Anrig B, et al. Model-based diagnosis and probabilistic assumption-based reasoning[J]. Artificial Intelligence, 1998, 104(1): 71-106
- [10] Heidtmann K D. Smaller Sums of Disjoint Products by Subproduct Inversion[J]. IEEE Transactions on Reliability, 1989, 38(3): 305-311
- [11] Kohlas J. Mathematical foundations of evidence theory [C] // Coletti G, Dubois D, Scozzafava R, eds. Mathematical Models for Handling Partial Knowledge in Artificial Intelligence. New York: Plenum Press, 1995: 31-64
- [12] Kohlas J, Haenni R. Propositional information systems[J]. Journal of Logic and Computation, 1999, 9(5): 651-681
- [13] Laskey K B, Lehner P. Assumptions, Belief and Probabilities[J]. Artificial Intelligence, 1989, 41(1): 65-77
- [14] Provan G M. A Logic-based Analysis of Dempster-Shafer Theory[J]. International Journal of Approximate Reasoning, 1990, 4

(5/6): 451-495

- [15] 邓勇. 基于模型诊断的贝叶斯解释及应用[J]. 上海交通大学学报, 2003, 37(1): 5-9
- [16] Tuhim S. An experimental study of criteria for hypothesis plausibility[J]. Journal of Experimental and Theoretical Artificial Intelligence, 1991, 3(2): 129-144
- [17] Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference[M]. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc, 1988: 120-145
- [18] Ahmed Y, Neufeld E. Model-based Diagnosis: A Probabilistic Extension[J]. Lecture Notes in Computer Science, 1998, 1455(1): 379-396
- [19] Flesch I, Lucas P. Conflict-based Diagnosis: Adding Uncertainty to Model-based Diagnosis[C]//Proceedings of the 20th International Joint Conference on Artificial Intelligence (IJCAI). 2007: 380-385
- [20] Flesch I, Lucas P. The Probabilistic Interpretation of Model-based Diagnosis[C]//European Conferences on Symbolic and Quantitative Approaches to Reasoning with Uncertainty. 2009: 204-215