

一种基于贝叶斯网络的模型诊断方法

赵进晓 肖 飞

(复旦大学电子工程系 上海 200433) (云南师范大学计算机科学与技术学院 昆明 650092)

摘 要 提出一种结合贝叶斯网络进行基于模型诊断的方法。在基于模型诊断的基础上,建立了元件状态模型,并将诊断模型转换为贝叶斯网络,利用团树算法求解征兆产生时系统状态的后验概率,再通过计算边缘分布获得元件故障概率。最后给出一个数字故障电路的实例,在 Matlab 上进行推理,得到了精确的概率值,验证了该方法的有效性。

关键词 贝叶斯网络,基于模型诊断

Method of Model-based Diagnosis Founded on Bayesian Network

ZHAO Jin-xiao XIAO Fei

(Department of Electronic Engineering, Fudan University, Shanghai 200433, China)

(College of Computer Science and Information Technology, Yunnan Normal University, Kunming 650092, China)

Abstract Put forward a method which applies bayesian network to the model-based diagnosis. Building a component-state model which is founded on the model-based diagnosis, authors got the posterior probability of system state in case the appearance of certain symptoms through junction tree algorithm. The component fault probabilities were obtained by the calculation of marginal distribution. An example of fault digital circuit was given. Making use of Matlab, the accurate probabilities were got. Therefore, the method was proved out.

Keywords Bayesian network, Model-based diagnosis

1 引言

诊断学(diagnostics)源出于医学语境,但现在早已超出这一局限,在工业、农业以及社会、经济等众多领域都有着广泛的应用。基于模型的诊断(Model-based diagnosis)是故障诊断研究中一个活跃的分支。1976年,de Kleer在文献[3]中首次使用“模型”(model)这一术语,1987年,Reiter在文献[5]中对基于一致性的模型诊断给出了完备的形式化描述。模型诊断的基本思想是依据系统逻辑模型和输入,推测系统正常情况下的预期行为,称与系统预期存在差异的实际观测为征兆,当征兆出现即系统存在故障时,通过推理确定引发故障的元件组合。

按照文献[5]的方法,可以求得一组在逻辑上完备的、能够对征兆进行解释的系统状态,但无法给出概率值来反映每一元件发生故障的可能性。文献[2,3]考虑在排除系统不可能状态后,对逻辑上允许的状态集所对应的概率空间归一化,并分别对每一元件求取边缘分布作为其故障概率,由此可以获得元件故障可能性的数值度量,对故障定位具有一定的参考价值。但这种方法将所有逻辑上可能的系统状态对征兆的支持程度等同视之,使元件故障概率值带有系统性误差。针对这一问题,本文引入贝叶斯网络的思想,添加元件状态模型,将诊断转化为在元件先验故障率预计基础上,凭借观测值获得后验估计的信度更新过程。由于该方法充分利用了待诊断系统拓扑结构蕴涵的条件信息,区分了系统处于各个状态

时产生征兆的不同可能性,因此得到了更为合理的元件故障概率。

2 从诊断模型向贝叶斯网络转化

一个基于模型诊断的故障系统表示为一个三元组(SD , $COMPS$, OBS),其中 SD 为系统描述,为一阶句子集合; $COMPS$ 为系统组成部分,是一个有限的常量集; OBS 为观测集,是一个一阶句子集合。如图1所示的故障数字电路, m_1 , m_2 , m_3 为乘法器, a_1 , a_2 为加法器。当输入 $in1=2$, $in2=3$ 时,若系统正常,输出应为 $out1=out2=12$ 。然而实际观测时, $out2=12$, $out1=10$,显然系统发生故障。




图1 数字故障电路

该故障电路可以描述为:

$OBS = \{in1=2, in2=3, out1=10, out2=12\};$

$COMPS = \{m_1, m_2, m_3, a_1, a_2\};$

$SD = \{multiplier(x) \wedge \neg ab(x) \rightarrow out(x) = in1(x) \times in2(x), adder(x) \wedge \neg ab(x) \rightarrow out(x) = in1(x) + in2(x)\} \cup \{m_1, m_2, m_3, a_1, a_2 \text{ 拓扑逻辑}\}.$

按照 Reiter 在文献[1]中提出的方法进行逻辑推理,可以得到最小冲突集 $C_1=[m_1, m_2, a_1]$, $C_2=[m_1, m_3, a_1, a_2]$, 用求碰集的方法得到 4 个诊断: $[m_1]$, $[a_1]$, $[m_2, m_3]$, $[m_2, a_2]$ 。实际上,诊断与最小冲突集是一对双射,由最小冲突集可以确定诊断,反之亦然。假设系统由元件集合 $C=\{c_1, c_2, \dots, c_n\}$ 组成,每一元件可用一个布尔变量 x_i 来表示其状态, $x_i=1$ 时元件正常, $x_i=0$ 时元件故障。于是,一个处于 $(0,1)^n$ 上的布尔向量 X 可以表示所有的系统状态,例如,在图 1 所示系统中,当 x_1, x_2, x_3, x_4, x_5 分别对应 m_1, m_2, m_3, a_1, a_2 时, $X=(1,1,1,1,1)$ 表示所有的元件都正常。当待诊断系统的最小冲突集或者诊断已知时,系统所处的状态即可划分为两部分,一部分在逻辑上可以作为观测的解释,另一部分对观测来说则是不可能状态。在图 1 所示系统中,由于含有 5 个元件,总共有 $2^5=32$ 种系统状态,其中有 5 个状态是不可能状态,它们分别对应最小冲突集及其超集,罗列如下: $(1,0,1,1,1), (1,1,1,1,1), (1,1,0,1,0), (1,1,1,1,0), (1,1,0,1,1)$ 。由此,对于一个给出拓扑结构的故障系统,可以从逻辑上清楚地求得诊断结果。

然而,面对实际故障系统,相比逻辑可能性,我们更为关心的往往是元件故障的量化指标,如元件故障概率。另一方面,同样是逻辑上与观测一致的状态,不同的系统状态发生时,征兆出现的条件概率却差别很大。因此,如同文献[2,3]的处理,将具备逻辑可能性的状态先验概率累加求和并归一化后再计算元件故障率的边缘分布显然忽略了条件关系的制约。仍以图 1 所示为例,从逻辑上讲,系统处于 $(1,0,1,0,1)$ 及 $(1,0,1,1,1)$ 两状态均可对观测做出解释。但是当系统处于前者时,要求 m_2 与 a_2 同时发生故障的前提下,且两者故障的效应相互抵消,以至在 $out2$ 端输出与预期吻合,这在逻辑上是正确的,但从概率来讲,则是小概率事件,可能性微乎其微。此外,观测值与预期相符对逻辑诊断不提供任何信息,这显然不够合理。

为了求出已获得观测值时,系统处于各个状态的概率,我们引入贝叶斯公式。设系统由 n 个元件组成,则系统状态总数为 2^n 种,分别记为 $X_i, i=1,2,\dots,2^n$ 。对于任一系统状态 X_i ,其后验概率:

$$P(X_i/OBS) = \frac{P(X_i) \cdot P(OBS/X_i)}{\sum_{i=1}^{2^n} P(X_i) \cdot P(OBS/X_i)} \quad (1)$$

其中, $P(X_i)$ 是系统处于状态 X_i 的先验概率, $P(OBS/X_i)$ 是系统处于状态 X_i 时产生观测值的条件概率。当 X_i 是逻辑上不允许的状态时, $P(OBS/X_i)=0$, 于是 $P(X_i/OBS)=0$, 这与逻辑诊断的结果一致。利用贝叶斯公式求解后验状态概率的难点在于无法利用系统几何拓扑结构提供的条件独立关系,计算量巨大且难以通过程序执行,而贝叶斯网络恰恰是解决这一问题的有效手段。

3 一个数字故障电路实例

Pearl 提出的贝叶斯网络^[1] 是进行不确定性推理的概率图模型,其基本结构是一个有向无圈图,图中节点代表随机变量,节点间的边代表变量之间的直接依赖关系。每个节点都指派有一个概率分布,根节点 X 所指派的是边缘分布 $P(X)$, 而非根节点 X 所指派的是条件概率 $P(X|\pi(x)), \pi(X)$ 表示节点 X 所有父节点的联合概率分布。在定性层面,贝叶斯网

络用一个有向无圈图描述了变量之间的依赖和独立关系;在定量层面,它则利用条件概率分布刻画了变量对其父节点的依赖关系。

为了借助贝叶斯网络进行故障诊断,我们需要从如图 1 所示的系统模型转化为贝叶斯网络,具体步骤如下:

- ①系统中所出现的信号均视为变量,并添加元件状态变量,每一变量对应一个节点。
- ②每一元件的输出信号所对应节点的父节点包括输入元件信号变量节点和元件状态变量节点。在每一对父子节点之间添加有向边。
- ③对每一个元件状态节点指派元件先验故障率。
- ④描述元件正常和非正常时的行为。
- ⑤为每一个非根节点指派条件概率。

依照上述方法,从图 1 所示系统可以得到如图 2 的贝叶斯网络,其中节点 in_1, in_2, X, Y, Z 为信号节点, m_1, m_2, m_3, a_1, a_2 为元件状态节点。设乘法器 m_1, m_2, m_3 的正常工作概率为 $P_m=0.95$, 加法器 a_1, a_2 的正常工作概率为 $P_a=0.98$, 同时输入信号 in_1, in_2 分别以概率 1 取 2 和 3, 则所有图 2 中根节点的先验概率如表 1 所示。假定乘法器和加法器均为 4 位,当它们工作不正常时,输出值为一离散随机变量,其分布律为 0 到 15 上的均匀分布,则每一个其间的数值都以概率 Δ ($\Delta=1/16$) 取到,由此可计算得到图 2 中所涉及的所有条件概率,陈列如表 2, 表 3, 表 4 所示。




图 2 故障电路贝叶斯网络

表 1

$P(in1=2)$	$P(in2=3)$
1	1
$P(a1=T)$	$P(a1=F)$
$P(a2=T)$	$P(a2=F)$
P_a	$1-P_a$
$P(m1=T)$	$P(m1=F)$
$P(m2=T)$	$P(m2=F)$
$P(m3=T)$	$P(m3=F)$
P_m	$1-P_m$

表 2

$m1$	$in1$	$in2$	$P(X=T)$	$P(X=F)$
T	T	T	1	0
F	T	T	Δ	$1-\Delta$

表 3

$a1$	X	Y	$P(out1 \neq 10)$	$P(out1=10)$
T	T	T	1	0
	T	F	$1-\Delta$	Δ
	F	T	$1-\Delta$	Δ
	F	F	$1-10 \cdot \Delta^2$	$10 \cdot \Delta^2$
F	...	...	$1-\Delta$	Δ

已经与网络中顶点集 V 和边集 E 没有关系了,却受到了网络参数(图中的 N)的直接影响。

改进的算法是每次都沿一条最短的增流路径进行增流,最短是指路径所包含的边数最少。若采用先标记先检查,对网络进行广度优先搜索,就能达到这个目的。具体方法如下:

对上面的第 3 步改进为按 BFS 次序先标记先检查,选择最先标记但尚未检查的顶点,若该顶点的所有邻接顶点均已标记,则转第 7 步,否则对所有未标记的邻接顶点进行标记,然后转第 4 步。

4 算法的实现和分析

以上面的网络为例,在给定的网络中从源顶点 S 出发,根据通信链路的容量,选容许流 $V(F)$,该相关顶点进行标记,得到图 3 的结果。




图 3 第一次标记




图 4 第二次标记

显然存在有一条增流路径 $P_1 = S \rightarrow A \rightarrow B \rightarrow T (\Delta P_1 = 3)$ 。在相应的通信链路上标记容许流 $V(F)$,在完成增流路径的操作以后,再进行第二次标记,得到图 4 的结果。

(上接第 292 页)

表 4

a2	Y	Z	$P(\text{out}2 \neq 12)$	$P(\text{out}2 = 12)$
T	T	T	0	1
	T	F	$1 - \Delta$	Δ
	F	T	$1 - \Delta$	Δ
	F	F	$1 - 12 \cdot \Delta^2$	$12 \cdot \Delta^2$
...	...	...	$1 - \Delta$	Δ

至此,贝叶斯网络已经构建完成。由于该贝叶斯网络中有环存在,利用网址^[4]提供的 Bayesian Network 工具箱中联合树算法引擎进行推理计算,获得各元件故障概率分别如下:

$$P(m_1) = 0.6806, P(m_2) = 0.0492, P(m_3) = 0.0079$$

$$P(a_1) = 0.2903, P(a_2) = 0.0022$$

上述结果与文献[2,3]进行比较可发现元件 m_2 的故障概率下降了约 50%,元件 a_2 的故障概率下降了约 25%,而这正是因为条件概率的引入使得两个故障叠加后系统行为正常的概率下降,与我们之前的分析一致。

结束语 本文讨论了利用贝叶斯网络进行模型诊断的方

又发现有增流路径,继续操作。然后再作标记,调整相应的通信链路上标记容许流 $V(F)$,直到整个网络拓扑图搜索完成,得到图 5 的结果,解决了网络流的问题。




图 5 标记完成后的网络流

下面对该算法的复杂性进行分析,该算法每次都需要寻找网络中最短的增流路径,它可能只有一条边,但是最长时可能达到 $|V| - 1$ 条边。若将增流路径所含边的总数称为长度,那么网络中就可能存在长度为 $1, 2, \dots, |V| - 1$ 的增流路径。使用 BFS 搜索网络是,寻找一条增流路径在最坏情况下需要遍历网络中所有的边 $O(|E|)$ 。为了找到所有长度的边,在最坏情况下算法须执行 $O(|V| \cdot |E|)$ 。同时,每次调整过程中修改一条增流路径时,在最坏情况下算法的复杂度为 $O(|E|)$ 。因此,整个算法的复杂度就是 $O(|V| \cdot |E|^2)$,算法可以用 Java 实现。

结束语 网络流量问题的讨论在实际生活中也有意义,许多系统中都包含了流量问题,例如,公路系统中的车流量,控制系统中有信息流,供水系统中有水流量,金融系统中有现金流等。该方法具有一定的普遍性,也可以应用到这类系统中去,这些由“源”产生的流,经过复杂的中转网络,到达目的地“宿”,为了获得尽可能好的性能,可以转化为最大流的分析。

参考文献

- [1] Andrew S. Tanenbaum, Computer Network, Fourth Edition. Pearson Education North Asia Limied, 2004
- [2] 胡金初. 计算机网络. 高等教育出版社, 2006

法。文献[1]提出过采用贝叶斯网络进行模型故障诊断的思路,但未能结合团树算法(Junction Tree Algorithm)求出元件故障概率,本文给出了精确的概率值,这是本文的最大创新点。后续工作将考虑采用信息熵作为判据,结合贝叶斯网络进行故障诊断。

参考文献

- [1] Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference. 2nd ed. San Mateo, CA: Morgan Kaufmann, 1991
- [2] Kohlas J, Anrig R, Haenni R. Model-based diagnosis and probabilistic assumption-based reasoning[J]. Artificial Intelligence, 1998, 104(1): 71-106
- [3] 邓勇,等. 基于模型的贝叶斯诊断及应用[J]. 上海交通大学学报, 2003, 30(1): 5-8
- [4] <http://www.cs.ubc.ca/~murphyk/Software/BNT/bnt.html>
- [5] Retiter R. A theory of diagnosis from first principles[J]. Artificial Intelligence, 1987, 32(1): 57-95