机载燃油系统在线实时健康管理

冯 威 于劲松 袁海文 刘 浩

(北京航空航天大学 自动化科学与电气工程学院, 北京 100191)

摘 要: 针对机载燃油系统在线实时健康管理存在的观测信息不确定性、任务完成时限性的问题,研究了国内外最新健康管理算法,提出了机载燃油系统健康模型构建、在线实时推理的方法. 该方法基于系统结构模型,采用面向对象方法构建 BN(Bayesian Network)健康模型,并利用 GVE(Global Variable Elimination)算法离线编译 BN 健康模型,构造 AC(Arithmetic Circuit)健康模型. 仿真结果表明:与 BN 健康模型相比,所设计的 AC 健康模型在观测信息存在不确定性的情况下,能够高精度在线诊断系统故障,也可以有效满足健康管理严格时限性要求.

关 键 词: 贝叶斯网络; 健康管理; 燃油系统; 在线实时; 运算电路

中图分类号: TP 206$^+$. 3

文献标识码: A **文 章 编 号**: 1001-5965(2013)12-1639-05

Online real-time health management for aerial fuel delivery system

Feng Wei Yu Jinsong Yuan Haiwen Liu Hao

(School of Automation Science and Electrical Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: To address the problems of observational information uncertainties and task deadlines encountered in the online real-time health management(HM) for aerial fuel system(AFS), the latest HM algorithms in China and aboard were researched, and an approach for health modeling and online real-time reasoning of AFS was proposed. The object-oriented method was used to develop BN health model based on the system structure model, and the global variable elimination(GVE) algorithm was applied to the offline compilation of this BN into an arithmetic circuit(AC) health model. The simulation results show that the AC, compared with the Bayesian network, can not only provide precisely online diagnosis of system faults, but also effectively meet the strict time deadlines for HM requirements, under the condition of observational information uncertainties.

Key words: Bayesian networks; health management; fuel system; online real-time; arithmetic circuit

机载燃油系统(AFS,Aerial Fuel System)作为飞行器的关键组成部分,在设计时常采用双余度或冷热备份式系统,甚至采用多余度系统. 由于 AFS 结构的复杂、飞行器计算资源的限制使得其在线实时健康管理(HM,Health Management)存在观测信息不确定性、任务完成时限性的问题.

针对此问题,许多学者提出了解决办法. 如 Maximin[1]、反馈法[2]能有效处理观测信息不确定问题,但存在健康模型精度差或收敛慢的缺陷;故障树[3]、多信号流图[4]以布尔变量(双态)形式表示系统的健康状态,并不适用解决多态或健康状态定量计算问题;模糊逻辑[5]运用模糊集合来研究系统内在规律、并采用模糊规则(IF/THEN)来推理系统行为,对于复杂系统,增加的量化级数将导致规则搜索范围变大、数据量增多,从而降低决策速度及推理精度;神经网络[6]通过对标准模

收稿日期: 2013-01-21; **网络出版时间**: 2013-12-04 09:48

网络出版地址: www.cnki.net/kcms/detail/11.2625.V.20131204.0948.001.html

基金项目: 航空科学基金资助资助项目(2010ZD11007,20100751010)

作者简介: 冯 威(1980-),男,湖南湘潭人,博士生,fengyun1005@sina.cn.

式样本的学习不断修正网络权值,可以贴近任意真实系统,然而模型精度依赖于样本充分性及自身网络结构,且存在黑盒效应;BNs(Bayesian Networks)[7]是一种描述随机变量直接信赖关系的因果图模型,可认为是目前不确定知识表达和推理最有效的理论模型之一,但其精确推理算法存在计算资源消耗大的缺陷[8],虽然 Monte Carlo 采样、Gibbs 采样等近似推理算法能缓解该问题,但近似推理算法是一种以牺牲精度换取资源的折中处理方法. 而 CBN(Compiling Bayesian Network)[9-10]方法在继承 BNs 强大的不确定性问题处理能力的同时,由于将健康监测分解为离线编译和在线推理过程,使得计算资源集中消耗在离线编译构建 AC(Arithmetic Circuit)的过程中,而 AC 在线推理则仅需消耗极少的计算资源,但如何在 HM 中使用 CBN,尚待研究与验证.

本文分析 AFS 结构模型,利用面向对象方法构建了 BN 健康模型. 为解决 BN 在线推理计算资源消耗大的问题,基于 BN 所蕴含的网络线性多项式(NMLF, Network Multi-Linear Function), 采用全局消元算法(GVE, Global Variable Elimination)离线构建了 AC 健康模型. 由于 BN 结构稳定,此过程仅需执行一次,而构建的 AC 则可重复用于后续在线推理. 与 BN 相比,AC 在线推理在保证诊断精度的同时,仅需占用极少的计算资源(10% 以下).

1 AFS 健康模型

1.1 系统结构模型

为透彻讨论 AFS 在线实时 HM 方法,现以图 1 所给出的简单 AFS 结构模型为例进行说明. 该模型主要参考联合攻击战斗机(JSF, Joint Strike Fighter)燃油系统模型[11],由主油箱、两个辅助油箱(1,2)组成,其工作状态有两种:

1) 主油箱液位高于预设报警门限 F_{th} 时,主油箱工作,辅助油箱(1,2)处于待机状态;

2) 主油箱液位低于预设报警门限 F_{th} 时,控制器开始工作,通过对油泵电源开关实施控制,以保证辅助油箱(1,2)依序向主油箱输送燃油.

以获取完备的 HM 观测信息(传感器采样值)为原则,AFS 传感器设置如图 1 所示(由于篇幅限制,本文对传感器优化设置方法不做讨论). 为解决增加的传感器所引入的额外故障,本文将其纳入系统 HM 监测. 表 1 给出了组件(含传感器)健康状态(故障模式)及概率分布情况.

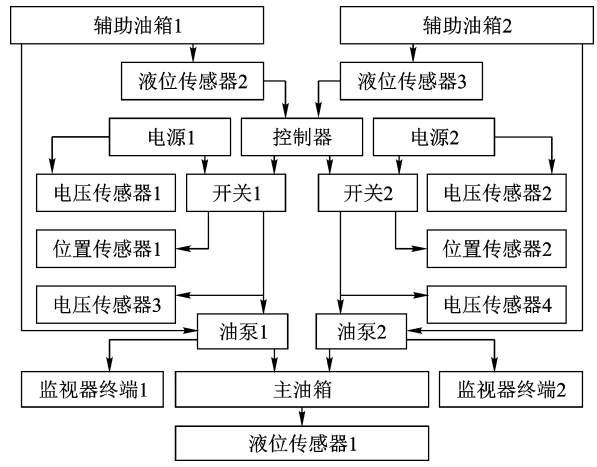


图 1 AFS 结构模型

表 1 AFS 组件健康状态及概率分布

组件		健康/概率	故障 1/概率	故障 2/概率
基础组件	油箱	健康/0.90	泄漏/0.05	残渣/0.05
	电源	健康/0.90	常高/0.05	常低/0.05
	开关	健康/0.90	常闭/0.05	常开/0.05
	油泵	健康/0.90	密封/0.05	残渣/0.05
	控制器	健康/0.90	硬件/0.05	软件/0.05
	终端	健康/0.90	硬件/0.05	软件/0.05
传感器	电压 S_V	健康/0.99	常高/0.005	常低/0.005
	液位 S_F	健康/0.99	常高/0.005	常低/0.005
	开关 S_P	健康/0.99	常闭/0.005	常开/0.005

1.2 BN 健康模型

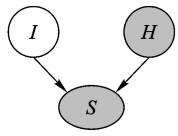
考虑 BN 强大的不确定性问题处理能力,本节将以 AFS 结构模型为基础,采用 OO(Object-Oriented)方法并结合某飞行研究所提供的专家知识自底向上构建 BN 健康模型,流程步骤如下:

1) 依据 AFS 组件自身固有的因果关系构建组件 BN 子类. 图 2 给出电压传感器 BN 子类示意图,其中节点 Health 为健康监测节点. 该 BN 子类所对应的概率参数如表 2 所示.

表 2 电压传感器 BN 子类概率参数

条件概率分布			联合概率分布
$P(I)$	$P(H)$	$P(S \mid I, H)$	$P(S,I,H)$
高/0.5	健康/0.99	高/0.99	0.5×0.99×0.99=0.49005
高/0.5	健康/0.99	低/0.01	0.5×0.99×0.01=0.00495
高/0.5	常高/0.005	高/0.99	0.5×0.005×0.99=0.002475
高/0.5	常高/0.005	低/0.01	0.5×0.005×0.01=0.000025
高/0.5	常低/0.005	高/0.01	0.5×0.005×0.01=0.000025
高/0.5	常低/0.005	低/0.99	0.5×0.005×0.99=0.002475
低/0.5	健康/0.99	高/0.01	0.5×0.99×0.01=0.00495
低/0.5	健康/0.99	低/0.99	0.5×0.99×0.99=0.49005
低/0.5	常高/0.005	高/0.99	0.5×0.005×0.99=0.002475
低/0.5	常高/0.005	低/0.01	0.5×0.005×0.01=0.000025
低/0.5	常低/0.005	高/0.01	0.5×0.005×0.01=0.000025
低/0.5	常低/0.005	低/0.99	0.5×0.005×0.99=0.002475

2) 依据组件间存在的直接因果关系(如电压关系、燃油流动关系)将构建的 BN 子类进行集成,生成全局 DAG(Directed Acyclic Graph).

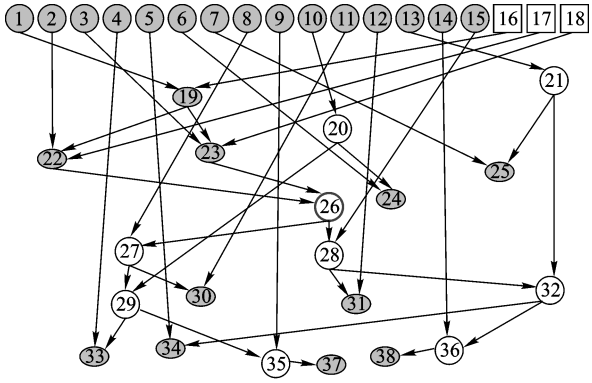


○—输入I; ●—健康H; ⬭—传感器S.

图 2　电压传感器 BN 子类

3) 依据专家经验知识为网络节点指定 CPT (Conditional Probability Table),再采用 EM (Expectation Maximization)算法对数据进行学习,使构建的 BN 更贴近 AFS 实际工作特性.

图 3 给出了依上述步骤所构建的 BN 健康模型. 但如本文前部分所述,BN 推理存在计算资源大的缺陷[8]. 下面考虑基于 CBN 思想,将 BN 离线编译为 AC 健康模型. 生成的 AC 将用于解决系统健康状态在线实时推理问题.



⬭—传感器节点S; ○—其他节点; ●—健康节点H; □—开关节点C.

图 3　机载燃油系统 BN 健康模型

1.3　AC 健康模型

1.3.1　NMLF

依据 CBN 思想,为图 3 所给出的 BN 健康模型分配指示因子与网络参数.

1) 指示因子:为 BN 的每个变量 X 分配指示因子 λ,用于指明 X 在确定时刻的实例化情况. 如某时刻 X 实例化为 x_1 则 λ 可设置为

$$\left.\begin{aligned}\lambda_{x_1} &= 1\\ \lambda_{x_2} &= 0\end{aligned}\right\} \tag{1}$$

2) 网络参数:为 BN 的每组家族成员 XU 分配网络参数 $\theta_{X|U}$(事件概率,其中 U 为 X 父节点).

基于上述原则,BN 所蕴含的 NMLF 可写为

$$f(\cdot) = \sum_{x}\prod_{xu\sim x}\lambda_x\theta_{x|u} \tag{2}$$

对于图 2 所给出的 BN,其 NMLF 可表示为

$$\begin{aligned}f(\cdot) = {}&\lambda_{i_1}\lambda_{h_1}\lambda_{s_1|i_1,h_1}\theta_{i_1}\theta_{h_1}\theta_{s_1|i_1,h_1}+\lambda_{i_2}\lambda_{h_1}\lambda_{s_1|i_2,h_1}\theta_{i_2}\theta_{h_1}\theta_{s_1|i_2,h_1}+\\ &\lambda_{i_1}\lambda_{h_2}\lambda_{s_1|i_1,h_2}\theta_{i_1}\theta_{h_2}\theta_{s_1|i_1,h_2}+\lambda_{i_2}\lambda_{h_2}\lambda_{s_1|i_2,h_2}\theta_{i_2}\theta_{h_2}\theta_{s_1|i_2,h_2}+\\ &\lambda_{i_1}\lambda_{h_3}\lambda_{s_1|i_1,h_3}\theta_{i_1}\theta_{h_3}\theta_{s_1|i_1,h_3}+\lambda_{i_2}\lambda_{h_3}\lambda_{s_1|i_2,h_3}\theta_{i_2}\theta_{h_3}\theta_{s_1|i_2,h_3}+\\ &\lambda_{i_1}\lambda_{h_1}\lambda_{s_2|i_1,h_1}\theta_{i_1}\theta_{h_1}\theta_{s_2|i_1,h_1}+\lambda_{i_2}\lambda_{h_1}\lambda_{s_2|i_2,h_1}\theta_{i_2}\theta_{h_1}\theta_{s_2|i_2,h_1}+\\ &\lambda_{i_1}\lambda_{h_2}\lambda_{s_2|i_1,h_2}\theta_{i_1}\theta_{h_2}\theta_{s_2|i_1,h_2}+\lambda_{i_2}\lambda_{h_2}\lambda_{s_2|i_2,h_2}\theta_{i_2}\theta_{h_2}\theta_{s_2|i_2,h_2}+\\ &\lambda_{i_1}\lambda_{h_3}\lambda_{s_2|i_1,h_3}\theta_{i_1}\theta_{h_3}\theta_{s_2|i_1,h_3}+\lambda_{i_2}\lambda_{h_3}\lambda_{s_2|i_2,h_3}\theta_{i_2}\theta_{h_3}\theta_{s_2|i_2,h_3}\end{aligned} \tag{3}$$

其中,每一因子项对应表 2 中的一项. 此时,如果 $s=s_1$,则指示因子可设置为

$$\lambda_X = \begin{cases}\lambda_{i_1} = 1\\ \lambda_{i_2} = 1\\ \lambda_{s_1} = 1\\ \lambda_{s_2} = 0\\ \lambda_{h_1} = 1\\ \lambda_{h_2} = 1\\ \lambda_{h_3} = 1\end{cases} \tag{4}$$

将式(4)代入式(3),则式(3)可简化为

$$\begin{aligned}f(\cdot) = {}&\lambda_{i_1}\lambda_{h_1}\lambda_{s_1|i_1,h_1}\theta_{i_1}\theta_{h_1}\theta_{s_1|i_1,h_1}+\lambda_{i_2}\lambda_{h_1}\lambda_{s_1|i_2,h_1}\theta_{i_2}\theta_{h_1}\theta_{s_1|i_2,h_1}+\\ &\lambda_{i_1}\lambda_{h_2}\lambda_{s_1|i_1,h_2}\theta_{i_1}\theta_{h_2}\theta_{s_1|i_1,h_2}+\lambda_{i_2}\lambda_{h_2}\lambda_{s_1|i_2,h_2}\theta_{i_2}\theta_{h_2}\theta_{s_1|i_2,h_2}+\\ &\lambda_{i_1}\lambda_{h_3}\lambda_{s_1|i_1,h_3}\theta_{i_1}\theta_{h_3}\theta_{s_1|i_1,h_3}+\lambda_{i_2}\lambda_{h_3}\lambda_{s_1|i_2,h_3}\theta_{i_2}\theta_{h_3}\theta_{s_1|i_2,h_3}\end{aligned} \tag{5}$$

最终得到的 $f(\cdot)$ 就是概率值 $P(s)$.

但直接采用 NMLF 实施健康推理,其计算资源代价将与采用 BN 相同[9].

1.3.2　离线编译

目前,离线编译构建 AC 的算法主要包括 NNF(Negation Normal Form)、ADD(Algebraic Decision Diagrams)、团树法及 GVE. NNF,ADD 在 BN 结构存在可局部优化特性(节点 CPT 中存在 0,1 概率,或存在相同概率取值事件)的情况下,可构建较小规模 AC(仅适用于该特定情况),而实际 AFS 由于观测信息具有不确定性,BN 很难满足可局部优化特性. 团树法利用 BN 全局结构来构建 AC(可适用于任意情况),但首先需要构建等价的团树,而最优团树的构建是 NP-hard 问题;GVE 也是一种全局性 AC 构造方法,由于算法更为直接、简单而在本文用于构建 AC 健康模型,其算法主要包括两部分:

1) 因子乘:给定变量集合 X 及概率 θ_X,变量集合 Y 及概率 θ_Y,因子乘可写为

$$\theta_Z = \theta_X\theta_Y \tag{6}$$

其中,$Z=X\cup Y$;实例化取值 z 与 x,y 兼容,也就是说,$x\sim z$,$y\sim z$;

2) 边缘和:给定变量集合 X 及概率 θ_X,变量集合 Y 及概率 $\theta_Y(X\subseteq Y)$,边缘和可写为

$$\theta_X = \sum_{Y\setminus X}\phi_Y \tag{7}$$

考虑一个包含 n 个随机变量的 BN,利用贝叶斯链式规则,其联合分布可表示为

$$P(X_1,X_2,\cdots,X_n)=\prod_{i=1}^{n}P(X_i\mid X_1,X_2,\cdots,X_{i-1}) \tag{8}$$

根据贝叶斯条件独立理论[7],有

$$P(X_i\mid X_1,X_2,\cdots,X_{i-1})=P(X_i\mid U_i) \tag{9}$$

依据式(9),式(8)则可以简化为

$$P(X_1,X_2,\cdots,X_n)=\prod_{i=1}^{n}\theta_{X_i\mid U_i} \tag{10}$$

此时,如果考虑从式(8)中剔除变量 X_k,等价于执行式(7)的边缘和操作,得

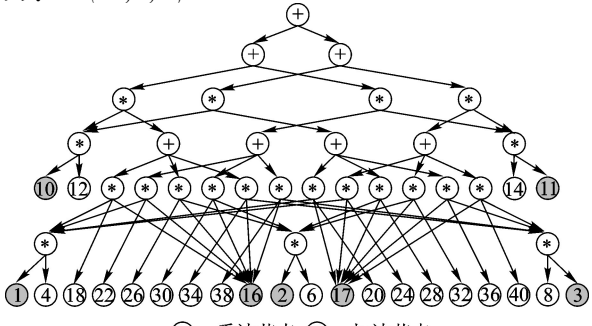
$$P(X_1,\cdots,X_{k-1},X_{k+1},\cdots,X_n)=\sum_{X_k}\prod_{i=1}^{n}\theta_{X_i\mid U_i} \tag{11}$$

因此,可采取先在式(10)中引入 λ,再对变量逐个消元的方法得到 NMLF,则式(2)可写为

$$f(\cdot)=\sum_{X_1}\cdots\sum_{X_n}\prod_{i=1}^{n}\lambda_{X_i}\theta_{X_i\mid U_i} \tag{12}$$

采用电路运算符“*”,“+”分别替换式(12)中的因子乘与边缘和来直接构建 AC. 另外,为保证构建的 AC 符合全局完整性且规模最小,本文在实施 GVE 前,采用最小插入边(min fill edges)算法[12]优化变量消元顺序.

例如图 2 的电压传感器 BN,依据上述原则所构建的 AC 健康模型如图 4 所示,其中消元顺序为:$E=\{H,I,S\}$.



⊛—乘法节点;⊕—加法节点;
Ⓝ—指示因子节点;Ⓝ—网络参数θ节点.

图 4 AC 健康模型

2 AC 在线实时推理

基于 AC 的在线实时推理步骤如下.

1) 根据获取的观测信息 s(传感器及计算机终端信息),采用式(1)设置各变量 λ_x,同时根据 BN 节点 CPT 设置网络参数 $\theta_{x|u}$;

2) 采用自底向上的方式依次计算节点的代数值 $V(X)$(子节点优先). 假设,节点 X 的子节点集合为$\{Y_1,Y_2,\cdots,Y_n\}$,则有

$$V(X)=\begin{cases}\sum_{i=1}^{n}Y_i & X\in\text{“+”}\\ \prod_{i=1}^{n}Y_i & X\in\text{“*”}\end{cases} \tag{13}$$

其中,根节点 R 的代数值 $V(R)$ 是所需的 $f(s)$.

3) 采用自顶向下的方式依次计算节点的微分值 $D(X)$(父节点优先). 节点的微分值 $D(X)$ 表示节点 X 的微小变化对根节点 R 的影响程度,等价于联合概率 $P(R,X)$. 在初始状态,可令根节点的 $D(R)=1$;对于其他节点 X,如果父节点为乘法节点“*”,则

$$D(X)=\frac{\partial V(R)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)}\frac{\partial V(p)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)}\frac{\partial\left(V(X)\prod_{X'\neq X}V(X')\right)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)}\prod_{X'\neq X}V(X') \tag{14}$$

如果父节点为加法节点“+”,则

$$D(X)=\frac{\partial V(R)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)}\frac{\partial V(p)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)}\frac{\partial\left(V(X)+\sum_{X'\neq X}V(X')\right)}{\partial V(X)}=\sum_{p}\frac{\partial V(R)}{\partial V(p)} \tag{15}$$

对于“+”父节点个数为 m,“*”父节点个数为 n 的特殊情况,则

$$D(X)=\sum_{i=1}^{m}\frac{\partial V(R)}{\partial V(p^i)}+\sum_{j=1}^{n}\frac{\partial V(R)}{\partial V(p^j)}\prod_{X'\neq X}V(X') \tag{16}$$

4) 根据步骤 2)~3)的计算结果,任意组件健康状态的后验概率为

$$P(h\mid s)=\frac{1}{f(s)}\frac{\partial f(s)}{\partial(\lambda_h)}=\frac{D(\lambda_h)}{V(R)}\quad H\notin S \tag{17}$$

3 应用验证

为了验证 AFS 的 AC 健康模型应用于在线实时 HM 的有效性,本文模拟了图 1 所给出的 AFS 在特定时刻 t 的健康状态如下:

1) 主油箱液位低于预设报警门限 F_{th}(状态 2),辅助油箱(1,2)液位都处于正常状态(状态 1),即 $s_{F_1}=2,s_{F_2}=1,s_{F_3}=1$;

2) 系统“电源 1”组件发生“常低”故障,即 $s_{V_1}=2,s_{V_2}=1,s_{V_3}=2,s_{V_4}=2,s_{P_1}=1,s_{P_2}=2,s_{m_1}=2,s_{m_2}=2$;

3) 系统终端监视器不发生故障,且不考虑控

制器信号传输延迟.

基于以上状态,采用第 2 节所讨论的步骤 1)设定指示因子 λ_x 及网络参数 $\theta_{x|u}$,根据步骤 2) ~ 3)在线计算各组件健康状态的后验概率.

图 5 给出了采用 AC 健康模型在线推理所得出的各组件健康状态后验概率分布的仿真结果.从图中可以看出,电源组件(见数字索引 13)处于故障模式 2(常低故障)的概率(83.86%)远大于其处于健康的概率(15.29%),而其他组件(包括传感器)处于健康的概率远大于处于故障模式 1 或故障模式 2 的概率,因此采用 AC 在线推理能正确隔离出系统故障. 详细在线推理结果见表 3.

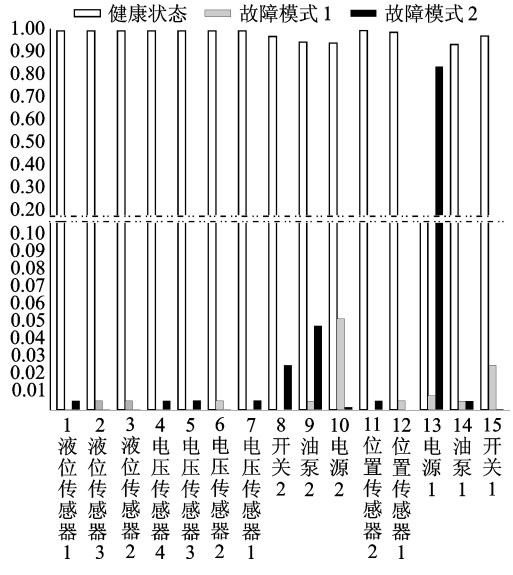


图 5　组件健康状态后验概率分布

采用 BN 健康模型在线推理同样能得到图 5 所示概率分布,但计算资源代价远大于 AC 健康模型(见表 3).从表 3 可以看出:①AC,BN 都能精确隔离真实故障(电源 1 的后验概率分布为:15.29%,0.85% 及 83.86%);②采用 AC 健康监测时,大部分的计算资源集中消耗在离线编译状态 (214 ms),而在线实时推理过程仅需占用极少的资源(20 ms);③采用 BN 推理时,计算资源全部集中消耗于在线推理过程(125 ms);④AC 在线推理计算资源消耗远小于 BN 在线资源消耗(20 ms≤125 ms).

表 3　计算资源代价及概率分布

健康模型	离线编译	在线推理		电源 1 健康状态概率分布/%		
		因子设置	推理时间/ms	健康	常高	常低
AC	214	1	19	15.29	0.85	83.86
BN	N/A	N/A	125			

4　结 束 语

基于仿真案例分析,可得出以下结论: ①BN 虽然具有强大的不确性问题处理能力,但推理时计算资源消耗大,不能满足复杂 AFS 在线实时 HM 时限性要求;②AC 在保留 BN 强大的不确性问题处理能力同时,能在线正确隔离机载燃油系统故障,且只需消耗极少计算资源,能满足 HM 实时性要求;③本文提出的"结构模型→BN 健康模型(AC 健康模型"的建模思想及 AC 在线实时推理方法,能有效解决机载燃油系统在线实时 HM 问题,并可推广应用于其它机载系统.

参考文献 (References)

[1] He Fei, Brown M, Yue Hong. Maximin and bayesian robust experimental design for measurement set selection in modelling biochemical regulatory systems[J]. International Journal of Robust and Nonlinear Control, 2010, 20(9): 1059-1078

[2] Fu Minyue, Xie Lihua. Quantized feedback control for linear uncertain systems[J]. International Journal of Robust and Nonlinear Control, 2010, 20(8): 843-857

[3] Manno G, Chiaccho F. MatCarloRe: an integrated fault tree and monte carlo simulink tool for the reliability assessment of dynamic fault tree [J]. Expert Systems with Applications, 2011, 39(12): 10334-10342

[4] Deb S, Pattipati K R, Raghavan V, et al. Multi-signal flow graphs: a novel approach for system testability analysis and fault diagnosis [J]. Aerospace and Electronic Systems Magazine, IEEE, 1995, 10(5): 14-25

[5] Ferreira C C T, Serra G L O. Fuzzy methodology for frequency response estimation of uncertain dynamic systems[J]. International Journal of Robust and Nonlinear Control, 2012, 22(9): 959-980

[6] Hagan M T, Demuth H B, Jesús O D. An introduction to the use of neural networks in control systems[J]. International Journal of Robust and Nonlinear Control, 2002, 12(11): 959-985

[7] Pearl J. Causality: models, reasoning, and inference [J]. IIE Transactions, 2002, 34(6): 583-589

[8] Choi A, Zheng Lu, Darwiche A, et al. A tutorial on bayesian networks for system health management [J]. Chapman and Hall/CRC Press, 2011, 10(1): 1-29

[9] Chavira M, Darwiche A. Compiling bayesian networks with local structure[C]//Kitano H. International Joint Conferences on Artificial Intelligence-05. Edinburgh, UK: Lawrence Erlbaum Associates Ltd, 2005: 1306-1312

[10] Darwiche A. A compiler for deterministic, decomposable negation normal form[C]//Manuela V. Proceedings of AAAI-02. Edmonton, AB: AAAI Press, 2002: 627-634

[11] Saha B. A model-based reasoning architecture for system-level fault diagnosis [D]. Georgia: Georgia Institute of Technology, 2008

[12] Huang C, Darwiche A. Inference in belief networks: a procedural guide [J]. International Journal of Approximate Reasoning, 1996, 15(3): 225-263

(编　辑:刘登敏)