

DOI:10.3969/j.issn.1673-4785.201503012

网络出版地址: <http://www.cnki.net/kcms/detail/23.1538.tp.20150518.0907.001.html>

动态不确定因果图在化工系统动态故障诊断中的应用

曲彦光¹, 张勤², 朱群雄¹

(1. 北京化工大学 信息科学与技术学院, 北京 100029; 2. 北京航空航天大学 计算机学院, 北京 100083)

摘要: 为了避免化工工程中经济及生命的损失, 有效及时检测出故障是十分必要的。动态不确定因果图(DUCG)是一种根据有向图实现动态不确定因果关系表达与推理的方法。其处理信息的特性, 对于目前规模庞大的化工过程故障诊断有着自身的优势。因此运用 DUCG, 通过构建对象系统知识库、对故障数据进行概率推理, 实现化工过程的故障诊断, 并针对化工过程的震荡信号, 对原 DUCG 系统的数据发送模块做出改进, 使之适用范围更全面。为了验证 DUCG 理论的有效性, 采用 TE 过程作为实验对象, 建立包含 54 个变量、114 条因果关系的 DUCG 模型。该模型对 TE 过程中的故障得到较高诊断排序概率, 诊断正确概率达到了 100%, 与贝叶斯网络的平均诊断正确概率 79.71% 相比, 说明了 DUCG 是一种行之有效的方法。

关键词: 化工过程; 动态不确定因果图; 故障诊断; TE 过程; 概率推理

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1673-4785(2015)03-0354-08

中文引用格式: 曲彦光, 张勤, 朱群雄. 动态不确定因果图在化工系统动态故障诊断中的应用[J]. 智能系统学报, 2015, 10(3): 354-361.

英文引用格式: QU Yanguang, ZHANG Qin, ZHU Qunxiong. Application of dynamic uncertain causality graph to dynamic fault diagnosis in chemical processes[J]. CAAI Transactions on Intelligent Systems, 2015, 10(3): 354-361.

Application of dynamic uncertain causality graph to dynamic fault diagnosis in chemical processes

QU Yanguang¹, ZHANG Qin², ZHU Qunxiong¹

(1. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China; 2. School of Computer Science and Engineering, Beihang University, Beijing 100083, China)

Abstract: In chemical processes, it is necessary to effectively diagnose the fault on time in order to avoid losses of economy and lives. Dynamic uncertain causality graph (DUCG) is a method, which represents and infers the dynamic, uncertain causalities of the process system according to directed graph. Based on the characteristics of processing information, DUCG has its own advantages for fault diagnosis in chemical processes on a large scale. Therefore, this article applies DUCG to realize fault diagnosis of chemical processes by constructing the object system knowledge base and probabilistic reasoning on fault data. The data transmission module of the former DUCG system is improved to deal with the vibrational signals in the chemical process, and to widen the scope of application. The Tennessee Eastman (TE) simulator is taken as the experimental subject to test the effectiveness of DUCG methodology and software. 54 variables and 114 causalities are included in the constructed DUCG knowledge model. According to this model, all the failures simulated by TE are diagnosed in a high probability of ranking. The correct diagnosis rate is 100%. In comparison of Bayesian Network (BN), the mean correct diagnosis rate is 79.71% reportedly, showing that DUCG is an effective method.

Keywords: chemical process; dynamic uncertain causality graph; fault diagnosis; Tennessee Eastman (TE) process; probabilistic reasoning

迅速有效地诊断出一个复杂系统的故障是所有

过程专家和现场工作人员的主要目的之一。这一举措不仅能提高产量, 提升经济效益, 还能降低事故发生的风险。目前已有许多学者提出了不同故障诊断的方法。大体来讲, 这些方法可分为 3 类: 基于知识

收稿日期: 2015-03-09. 网络出版日期: 2015-05-18.

基金项目: 国家自然科学基金资助项目(61273330; 61473026).

通信作者: 张勤. E-mail: zhangqin@buaa.edu.cn.

朱群雄. E-mail: zhuqx@mail.buct.edu.cn.

的方法、基于模型的方法以及基于数据驱动的方法。像专家系统、模糊逻辑这些基于知识的方法^[1],是利用根据系统特性建立的定性模型。基于模型的方法,例如状态估计法及参数估计法^[2-4],是根据系统内的物理关系来组建系统的分析模型。一些基于数据驱动的方法,比如神经网络(ANN)^[5-6]或者主元分析法(PCA)^[7],是利用历史过程数据统计进行数学分析。上述提到的各种方法都已广泛应用到了各个领域。它们都有各自的优缺点,基于知识的方法比较依赖于专家的知识,而一些基于数据驱动的方法则需要大规模的历史数据才能得到比较准确的结果。因此近些年,多种故障诊断方法的结合算法被应用到各种过程中^[8-11]。

动态不确定因果图(dynamic uncertain causality graph, DUCG)是一种结合了定性模型与定量概率推理的新系统。这一方法根据知识来建立模型并根据严格的概率论来计算故障的概率,避免了单一定性或定量方法的缺陷。DUCG实现了不确定因果知识的简洁(compact)表达,并提供了有效的概率推理,使推理结果可以解释。作为一种新的知识表达与推理方法,DUCG已经应用到了医药领域^[12]及核电领域^[13]。

本文旨在证明DUCG是一种可以有效诊断化工系统故障的方法,在文献[14]的研究基础上,进一步完善了DUCG知识库的内容,使诊断结果更加准确,文献[14]中未能模拟并诊断的故障16在本文中得到了准确诊断;同时针对原DUCG系统在震荡型故障上诊断的不足,用新方法给出了改进的数据发送模块,调整了DUCG知识库建模,并取得了更理想的结果。

1 动态不确定因果图

1.1 DUCG 简介

DUCG是一个可以包含环路的有向图,图1展示了DUCG所应用的一些标准符号,这些符号的定义如下。

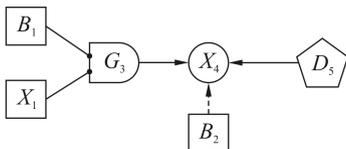


图1 DUCG 示例

Fig. 1 Illustration for DUCG

B_i 是DUCG中的基本变量(根变量), i 为变量标号, B_{ij} 为 B_i 处于 j 状态的事件。 B 类型变量(事件)只有输出,没有输入,在图中用矩形表示。

X_n 是DUCG中的结果或效果变量,在图中用圆形表示, n 为变量标号。 X_{nk} 为 X_n 处于 k 状态的事件。

G_n 是DUCG中的逻辑门变量,至少有2个输入,1个输出, G_{nk} 为 G_n 处于 k 状态的事件。逻辑门把其输入变量各状态的某种逻辑组合作为其一个状态,从而使DUCG的表达更加简洁。

D_n 是DUCG中的缺省事件,代表 X_n 的未知原因,用五边形表示。

实箭头表示连接变量,写为 $F_{n,i}$,是原因变量 V_i ($V \in \{B, X, G, D\}$)作用于结果变量 X_n 的作用变量。由于 V_i 和 X_n 有不同状态, $F_{n,i}$ 是一个矩阵,由 $F_{nk;ij}$ 组成。 $\Pr\{F_{nk;ij}\} = (r_{n,i}/r_n)\Pr\{A_{nk;ij}\} = (r_{n,i}/r_n)a_{nk;ij}$,其中 $A_{nk;ij}$ 代表 V_i 导致 X_{nk} 发生这一虚拟的因果作用事件,其发生概率为 $a_{nk;ij}$, $r_{n,i} > 0$ 为 V_i 和 X_n 之间存在因果关系的关联度, $r_n = \sum_i r_{n,i}$ 。

虚箭头表示条件作用变量,即仅当条件 $Z_{n,i}$ 满足时, $F_{n,i}$ 才成立,否则 $F_{n,i}$ 被删除。

1.2 DUCG 的概率推理

DUCG的概率推理基于如下假设:

假设 V_i 是 X_n 的父变量,那么有

$$\begin{aligned} X_{nk} &= \sum_i (r_{n,i}/r_n) \sum_j A_{nk,ij} V_{ij} \\ x_{nk} &= \sum_i (r_{n,i}/r_n) \sum_j a_{nk,ij} v_{ij} \end{aligned} \quad (1)$$

式中: $x_{nk} \equiv \Pr\{X_{nk}\}$, $v_{ij} \equiv \Pr\{V_{ij}\}$ 。

DUCG概率推理的第1项工作是根据接收到的证据对DUCG进行化简。当DUCG接收到了证据信息 E (通常为—组 X 变量的状态事件),就可以通过证据信息 E 中观测到的 X 变量的非正常状态实现DUCG的化简:不可能存在及无意义的变量和因果关系将在推理过程中被删除。化简的规则和细节详见参考文献[15],这些化简规则可以反复任意顺序使用直至DUCG无法继续化简。化简DUCG,不仅可以迅速找到问题区间,还可以在保证计算精确度的同时,大幅降低计算规模。

接下来第2项工作是对 E 中的事件按照式(1)进行逻辑展开,用以计算 $\Pr\{H_{kj}|E\} = \Pr\{H_{kj}E\}/\Pr\{E\}$,其中 H_{kj} 为待求的假设事件,亦即故障事件,通常为 B 类型事件,仅存于化简后的DUCG中。展开 $H_{kj}E$ 和 E

的方法相同,详见参考文献[15]。在展开的表达式中,只有 F 和 B 类型事件,将其发生概率代入即可计算 H_{kj} 的验后概率。

H_{kj} 的状态概率定义为 $h_{kj}^s \equiv \Pr\{H_{kj} | E\}$ 、排序概率定义为 $h_{kj}^r \equiv \frac{h_{kj}^s}{\sum_{H_{kj} \in S_H} h_{kj}^s}$ 。其中 S_H 为存在于化简 DUCG 中的所有可能故障假设的集合。当 S_H 中只有 1 个 H_{kj} 时,无需计算即可知 $h_{kj}^r = 1(100\%)$ 。

对于动态故障诊断,DUCG 目前采用的方法是假定各时间片 t_i 内的化简 DUCG 均包含待求故障假设 H_{kj} ,且证据 $E(t_i)$ 在给定 H_{kj} 的条件下独立,则用式(2)进行计算:

$$S_H(t) = \prod_{i=1}^n S_H(t_i)$$

$$h_{kj}^s(t) = \alpha_E(t) \prod_{i=1}^n h_{kj}^s(t_i) / (h_{kj}^s(t_0))^{n-1}$$

$$\alpha_E(t) \equiv \prod_{i=1}^n \Pr\{E(t_i)\} / \Pr\{E(t_i)\} \quad (2)$$

式中: $S(t_i)$ 为 t_i 时刻化简 DUCG 中的故障假设集合, t_0 为未收到故障信号前的时刻。

2 TE 过程

为了验证 DUCG 在故障诊断上的有效性,采用了 Tennessee Eastman (TE) 过程作为诊断的实例。TE 过程是由 Tennessee Eastman 公司设计的实际工业过程的仿真模拟,旨在开发、研究及评价过程控制理论和技术。Ricker 针对这一过程编译了 matlab 的仿真程序。本文采用了 Ricker 提供的程序,该 TE 过程的工艺流程图及采用的控制回路如图 2 所示。

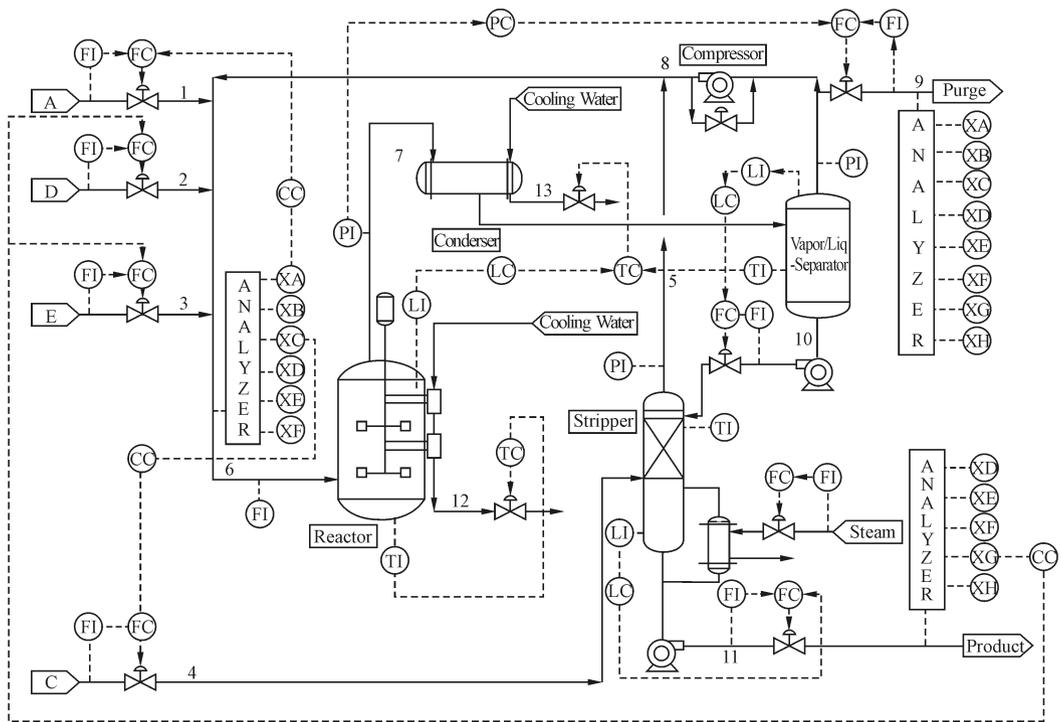


图 2 TE 过程工艺流程

Fig. 2 The Tennessee Eastman process

TE 过程由 5 个主要单元组成:反应器、冷凝器、汽提塔,气液分离装置及压缩机;TE 的生产过程包含 4 种气态的起始反应物:A、C、D、E,每种起始反应物都混有 1% 的惰性气体 B,它们被喂入反应器后会生成 2 种气态产物 G 和 H,同时会生成液态副产物 F。该过程包含了 41 个观测变量、12 个操作变量以及 20 个故障(见表 1)。故障 1 至故障 8 为数据阶跃变化的故障;故障 9 至故障 12 为数据随机变化的故障;故

障 13 是反应动力学缓慢漂移;故障 14 和 15 为数据称震荡趋势的阀门粘滞故障;故障 16 至故障 20 为未知故障。TE 过程被广泛的应用到各种不同研究领域来测试各种理论的实际效果。在故障诊断领域,像 PCA、贝叶斯网络(BN)等理论已经通过 TE 过程证明了其有效性。在本文中,TE 过程也用于验证 DUCG 理论的有效性,基于不同的故障,TE 过程的故障数据不仅可以当作离线数据来建立 DUCG 模型,同时可

以仿真成实时数据来验证 DUCG 的实时性。

表 1 TE 中模拟的故障

Table 1 Simulated faults in TE process

No.	故障	故障类型
1	A/C 进料比变化, B 组分不变	阶跃
2	B 组分变化, A/C 组分不变	阶跃
3	物料 D 温度	阶跃
4	反应器冷却水温度	阶跃
5	冷凝器冷却水温度	阶跃
6	物料 A 损失	阶跃
7	物料 C 压头损失	阶跃
8	A、B、C 组分	随机
9	物料 D 温度	随机
10	物料 C 温度	随机
11	反应器冷却水温度	随机
12	冷凝器冷却水温度	随机
13	反应器反应动力学	缓慢漂移
14	反应器冷却水阀门	粘滞
15	冷凝器冷却水阀门	粘滞
16	未知	—
17	未知	—
18	未知	—
19	未知	—
20	未知	—

3 TE 知识库的建立及诊断结果

3.1 TE 知识库的建立

要应用 DUCG 理论,首先要建立过程的 DUCG 知识库。知识库的建立步骤如下:

1) 根据目标过程建立变量列表,在 TE 过程中,故障被定义成 B 型变量,观测变量和操作变量被定义成 X 型变量。

2) 对 B 型及 X 型变量进行状态划分。

3) 定义 B 型变量的先验概率参数。

4) 根据专家经验建立子 DUCG。

5) 通过计算机将所有子 DUCG 合成,形成完整的 DUCG 知识库。

根据上述步骤,所建立的 TE 过程的知识库模型如图 3 所示。在这一 TE 过程的知识库中,一共选取了 54 个变量。其中有 20 个 B 型变量作为根变量,既 TE 过程的 20 个故障;还有由 25 个观测变量和 9 个操作变量组成的 34 个 X 型变量,通过这 34 个变量可

以清晰地观测到所有故障的传递过程。

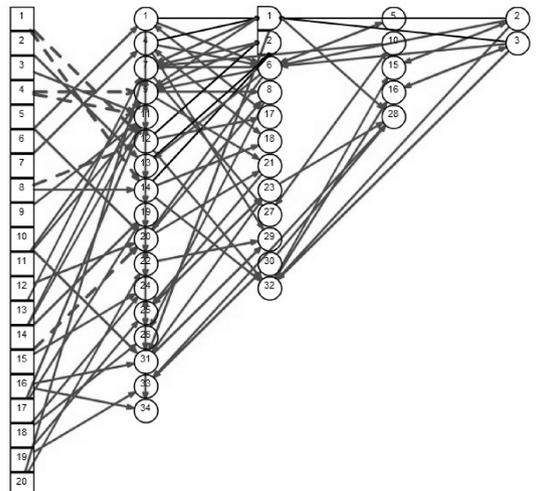


图 3 TE 过程知识库

Fig. 3 The knowledge base of TE process

与文献[14]建立的知识库相比,本知识库引入了变量 X_{34} ,使原先无法诊断出的故障 16 得出了良好的诊断结果,并对知识库的其他连接事件及连接强度进行了重新计算与调整。表 2 列出了 34 个 X 型变量的详细信息。

本文没有使用到子 DUCG(当然可以根据不同的分类建立子 DUCG),但是在大规模的系统中,子 DUCG 的存在就是十分必要的了。

表 2 X 型变量说明

Table 2 X-type variables

No.	变量名	No.	变量名
1	物料 A 进料流量	18	物料 C 阀门
2	物料 D 进料流量	19	反应器冷却水阀门
3	物料 E 进料流量	20	气液分离器温度
4	物料 A/C 进料流量	21	气液分离器液位
5	回流量	22	气液分离器压力
6	反应器进料流量	23	气液分离器出口流量
7	反应器压力	24	气液分离器冷却水温度
8	反应器液位	25	气液分离器阀门
9	反应器温度	26	冷凝器冷却水阀门
10	放空率	27	放空阀
11	反应器冷却水温度	28	汽提塔液位
12	反应器 A 组分含量	29	汽提塔压力
13	反应器 B 组分含量	30	汽提塔出口流量
14	反应器 C 组分含量	31	汽提塔温度
15	物料 D 阀门	32	产品中 G 组分含量
16	物料 E 阀门	33	汽提塔阀门
17	物料 A 阀门	34	汽提塔蒸汽流量

3.2 TE 过程的故障诊断

由于 TE 过程故障较多,本文只列举了几个典型的故障进行详细的讲述。

TE 过程的一个典型故障时 A/C 进料比发生变化,B 组分不变(故障 1),该故障类型为阶跃。从故障数据可以观测到该故障的异常状态为 $E = X_{1,2}X_{7,2}X_{9,1}X_{10,2}X_{12,1}X_{14,2}X_{17,2}X_{18,1}X_{22,2}X_{27,2}X_{29,2}$,其他 X 型变量的状态是正常的。当这些异常状态的信号被输入到 DUCG 后,DUCG 的推理机将开始工作,所有不相关或无意义的变量和因果关系都从 DUCG 中删除。图 4 展示了故障 1 的推理结果。在图 4 中,浅灰色表示变量的状态为高,深灰色表示变量的状态为低(不同颜色代表的不同状态可以查阅 DUCG 的变量列表),从图中可以很容易地理解故障 1 的推理结果。

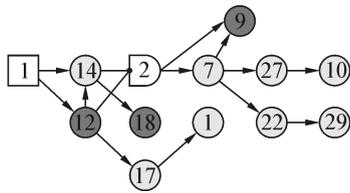


图 4 故障诊断结果

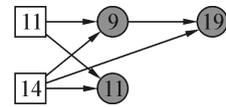
Fig. 4 The diagnosis result of TE process

故障诊断的推理结果和预计一样是正确的,因为只有 B_1 能引起所有图中的异常状态。由于推理结果中只有一个 B 型变量, B_1 是根据观测到的证据所得到的惟一结果, B 变量的先验概率及作用强度都可以忽略。

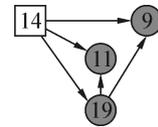
3.3 震荡型故障的处理方法

TE 过程的另一典型故障是反应器冷却水阀门粘滞(故障 14),该故障的故障数据呈震荡趋势。由于原 DUCG 采用的是只保留异常变量的初始状态这一方法,在处理化工过程普遍存在的震荡型故障存在着一些不足,无法准确推理出震荡故障的结果。针对这一问题,本文对数据发送模块重新进行了编译,采用了五点计数法、将震荡当作一个异常状态来处理,使诊断结果更加准确,更适用于化工系统。该方法设置检测到变量的状态为高的次数为 a ,检测到变量的状态的低的次数为 b ,当 $a+b=5$ 时,则令变量状态发送模块发送出震荡状态。从最初的故障数据可以观测到故障的异常状态为 $X_{9,1}, X_{11,1}, X_{19,1}$,其余的变量和因果关系被删除,经过一段时间后,震荡状态被检测出来,故障的异常状态更新为 $X_{9,5}, X_{11,5}, X_{19,5}$,并输入到 DUCG 中得到新的诊断结果。此方法不仅适用于处理震荡故障,同时也可以处理阶跃等各种类型的故障。图 5 展示了采用不同的处理方法对故障 14

的诊断结果。图 5(a)为采用原始方法得出的诊断结果,排序概率仅为 1.23%,图 5(b)为采用新方法得出的诊断结果,排序概率已达 100%。从图中可以明显发现,新的处理方法诊断的结果更加准确。



(a) 原始方法,排序概率为 1.23%



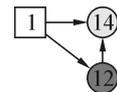
(b) 新方法,排序概率为 100%

图 5 故障 14 的诊断结果

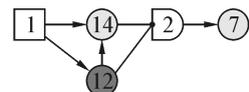
Fig. 5 The fault diagnosis result of fault 14

3.4 诊断结果

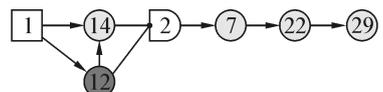
DUCG 可以清晰地描述故障的传递过程,如图 6 所示。在 t_1 时刻,DUCG 接收到了异常状态 $X_{14,2}$ 和 $X_{12,1}$;根据这 2 个异常状态,推理机给出了如图 6(a) 的推理结果: B_1 。当这 2 个状态引起异常状态 $X_{7,2}$ 发生并输入到推理机后,DUCG 转变成图 6(b) 所示的推理结果。随着时间的进一步推移,DUCG 的推理结果也如图 6(c)~6(g) 一样逐步展开,图 6(g) 便为包含了所有异常状态的最终展开结果。



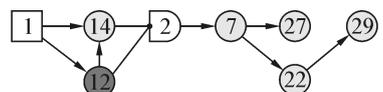
(a) t_1 时刻诊断结果



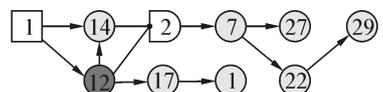
(b) t_2 时刻诊断结果



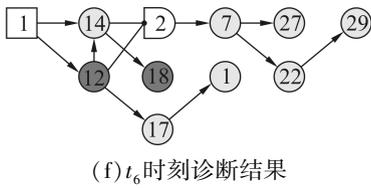
(c) t_3 时刻诊断结果



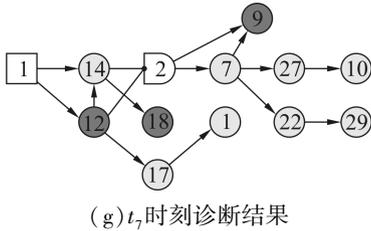
(d) t_4 时刻诊断结果



(e) t_5 时刻诊断结果



(f) t_6 时刻诊断结果

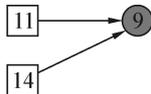


(g) t_7 时刻诊断结果

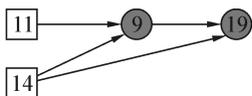
图 6 故障 14 的诊断结果

Fig. 6 The fault diagnosis result of fault 14

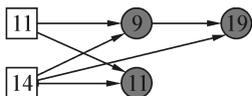
DUCG 不仅能展示故障随着时间的发展逐步展开的过程,随着更多证据的输入,DUCG 推理出的结果也越来越精确。由于故障 1 具有唯一的推理结果,这一过程未在上述结果中体现出来。因此图 7 中故障 14 的推理过程展示了推理结果随证据增加更加精确的过程。在震荡过程被检测到之前,由于在故障初始 B_{11} 与 B_{14} 具有相同的故障特征,推理机给出的推理结果为 B_{11} ,诊断概率如图 7(a) 所示仅为 0.4%,随着更多证据的输入,震荡状态被检测出来并输入到推理机,诊断概率就如图 7(d) 所示上升至 100%。



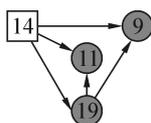
(a) t_1 时刻诊断结果,排序概率为 0.4%



(b) t_2 时刻诊断结果,排序概率为 0.99%



(c) t_3 时刻诊断结果,排序概率为 1.23%



(d) t_4 时刻诊断结果,排序概率为 100%

图 7 故障 14 的传递过程

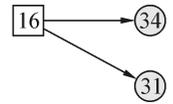
Fig. 7 The transfer process of fault 14

DUCG 在知识不完备的情况下也可取得良好的诊断结果。TE 过程的故障 16 为未知故障,其排序概

率如图 8 所示,也达到了 100%。



(a) t_1 时刻诊断结果



(b) t_2 时刻诊断结果

图 8 故障 16 诊断结果

Fig. 8 The fault diagnosis result of fault 16

不仅是上述 3 个故障,其余的 17 个故障也取得了不错的诊断结果,所有故障的排序概率如表 3 所示。

表 3 TE 过程排序概率

Table 3 Rank Probability of TE process

故障序号	排序概率/%	故障序号	排序概率/%
1	100	11	96.85
2	100	12	100
3	94.77	13	100
4	97.28	14	100
5	80	15	100
6	100	16	100
7	100	17	99.32
8	100	18	100
9	94.97	19	100
10	100	20	100

表 4 故障诊断结果

Table 4 The diagnosis results of TE process

故障序号	诊断正确概率/%	
	DUCG	BN
1	100	97.5
2	100	98.12
3	100	22
4	100	82.37
5	100	98
6	100	100
7	100	100
8	100	97
9	100	22.62
10	100	86.87
11	100	75.5
12	100	98.25
13	100	76.12
14	100	98.75
15	100	23.5
16	100	80.62
17	100	85
18	100	68.5
19	100	96.12
20	100	87.37

每一个故障的排序概率为该故障数据的概率分布,一般情况下,可以认为正确故障的概率分布大于 50%时(排在第一位),则诊断结果正确。所有故障诊断结果与贝叶斯网络诊断结果^[16]对比如表 4 所示。从结果看出 DUCG 针对 20 个故障的诊断都取得了正确的结果,所有故障的排序概率均高于 50%,诊断正确概率均达到 100%;与贝叶斯网络诊断结果相比,DUCG 诊断正确概率都要优于贝叶斯网络,尤其是故障 3、9、15 及 18 的诊断结果,DUCG 要远远优于贝叶斯网络。

4 结束语

本文将 DUCG 用于化工系统的故障诊断,以 TE 过程作为实验对象,针对化工系统特性重新编译了 DUCG 数据发送模块,调整构建了包含 54 个变量的 TE 过程知识库,并取得了不错的故障诊断效果。

通过分析实验结果,可以发现 DUCG 理论在故障诊断领域的优势:1) DUCG 可以随着时间的变化而变化,清晰地展示故障的传递过程。2) DUCG 可以实现实时的故障诊断,其实时性对实际的化工过程有着重要的意义。3) 可以将系统拆分由不同的领域专家建立子 DUCG,这样不仅有助于简化大型复杂系统的建立,同时也使构建的 DUCG 系统更加精确。作为一种基于知识的理论,DUCG 也存在着一些缺点,例如依赖于专家知识等。目前 DUCG 动态诊断方法基于每个时间片的化简 DUCG 都包含真实故障的假设。这对建造 DUCG 知识库提出了很高的要求。针对这一缺点,一种新的称为立体 DUCG 的算法正在开发当中。

参考文献:

- [1] ABDULGHAFOUR M, EL-GANAL M A. A fuzzy logic system for analog fault diagnosis [C]//1996 IEEE International Symposium on Circuits and Systems. Atlanta, USA, 1996: 97-100.
- [2] ICHALAL D, MARX B, RAGOT J, et al. An approach for the state estimation of Takagi-Sugeno models and application to sensor fault diagnosis [C]//Proceedings of the 48th IEEE Conference on Decision and Control, Jointly with the 28th Chinese Control Conference. Shanghai, China, 2009: 7789-7794.
- [3] BACHIR S, TNANI S, TRIGEASSOU J C, et al. Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines [J]. IEEE Transactions on Industrial Electronics, 2006, 53(3): 963-973.
- [4] REPPA V, TZES A. Fault detection and diagnosis based on parameter set estimation [J]. IET Control Theory and Applications, 2011, 5(1): 69-83.
- [5] DARWISH H A, TAALAB A M I, KAWADY T A. Development and implementation of an ANN-based fault diagnosis scheme for generator winding protection [J]. IEEE Transactions on Power Delivery, 2001, 16(2): 208-214.
- [6] MOREIRA M P, SANTOS L T B, VELLASCO M M B R. Power transformers diagnosis using neural networks [C]//International Joint Conference on Neural Networks. Orlando, USA, 2007: 1929-1934.
- [7] FERRACUTI F, GIANTOMASSI A, LONGHI S, et al. Multi-scale PCA based fault diagnosis on a paper mill plant [C]//2011 IEEE Conference on Emerging Technologies & Factory Automation. Toulouse, France, 2011: 1-8.
- [8] ZHAO X X, YUN Y X. A fault diagnosis method combined fuzzy logic with CMAC neural network for power transformers [C]//Chinese Conference on Pattern Recognition. Nanjing, China, 2009: 1-5.
- [9] LAU C K, GHOSH K, HUSSAIN M A, et al. Fault diagnosis of Tennessee Eastman process with multi-scale PCA and ANFIS [J]. Chemometrics and Intelligent Laboratory Systems, 2013, 120: 1-14.
- [10] KARIMI I, SALAHSHOOR K. A new fault detection and diagnosis approach for a distillation column based on a combined PCA and ANFIS scheme [C]//2012 24th Chinese Control and Decision Conference. Taiyuan, China, 2012: 3408-3413.
- [11] CHEN X Y, YAN X F. Using improved self-organizing map for fault diagnosis in chemical industry process [J]. Chemical Engineering Research and Design, 2012, 90(12): 2262-2277.
- [12] DONG C L, WANG Y J, ZHANG Q, et al. The methodology of dynamic uncertain causality graph for intelligent diagnosis of vertigo [J]. Computer Methods and Programs in Biomedicine, 2014, 113(1): 162-174.
- [13] ZHANG Qin, DONG Chunling, CUI Yan, et al. Dynamic uncertain causality graph for knowledge representation and probabilistic reasoning: statistics base, matrix, and application [J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(4): 645-663.
- [14] 杨佳婧, 张勤, 朱群雄. 动态不确定因果图在化工过程故障诊断中的应用 [J]. 智能系统学报, 2014, 9(2): 154-160.
YANG Jiajing, ZHANG Qin, ZHU Qunxiong. Application of dynamic uncertain causality graph to fault diagnosis in chem-

ical processes [J]. CAAI Transactions on Intelligent Systems, 2014, 9(2): 154-160.

[15] ZHANG Qin. Dynamic uncertain causality graph for knowledge representation and reasoning: discrete DAG cases [J]. Journal of Computer Science and Technology, 2012, 27(1): 1-23.

[16] VERRON S, TIPLICA T, KOBI A. Monitoring of complex processes with Bayesian networks [M] // REBAI A. Bayesian Network. Rijeka, Croatia: Sciyo, 2010: 213-228.

作者简介:



曲彦光,男,1990年生,硕士研究生,主要研究方向为动态不确定因果图及故障诊断。



张勤,男,1956年生,教授,博士生导师,博士,主要研究方向为动态不确定因果图理论及应用、系统可靠性评价与管理、知识产权理论及应用等。任国际原子能机构《与安全有关的专家系统》中方课题负责人,中国人工智能学会不确定性人工智能专业委员会主任。



朱群雄,男,1960年生,教授,博士生导师,博士,主要研究方向为智能建模与优化、数据挖掘与故障诊断。主持完成国家自然科学基金、国家“863”计划、省部级科研和企业工程项目20余项,获省部级科技进步一等奖2项、二等奖1项,发明专利和国家软件著作权10余项,发表学术论文200余篇。

第30届人工智能会议

The Thirtieth AAI Conference on Artificial Intelligence (AAAI-16)

February 12-17, 2016, Phoenix, Arizona USA

The Thirtieth AAI Conference on Artificial Intelligence (AAAI-16) will be held February 12-17 at the Phoenix Convention Center, Phoenix, Arizona, USA. Please note the alternate day pattern for AAAI-16. The workshop, tutorial, and doctoral consortium programs will be held Friday and Saturday, February 12 and 13, followed by the technical program, Sunday through Wednesday (at noon), February 14-17.

The chairs of AAAI-16 are Dale Schuurmans (University of Alberta) and Michael Wellman (University of Michigan). The purpose of the AAAI conference is to promote research in artificial intelligence (AI) and scientific exchange among AI researchers, practitioners, scientists, and engineers in affiliated disciplines. AAAI-16 will have a diverse technical track, student abstracts, poster sessions, invited speakers, tutorials, workshops, and exhibit and competition programs, all selected according to the highest reviewing standards. AAAI-16 welcomes submissions on mainstream AI topics as well as novel crosscutting work in related areas.

Timetable for Authors:

- ◇ July 1, 2015-September 10, 2015: Authors register on the AAAI web site
- ◇ September 10, 2015: Electronic abstracts due
- ◇ September 15, 2015: Electronic papers due
- ◇ October 28-30, 2015: Author feedback about initial reviews
- ◇ November 12, 2015: Notification of acceptance or rejection
- ◇ December 1, 2015: Camera-ready copy due

Website: <http://www.aaai.org/Conferences/AAAI/aaai16.php>