

基于 SVM-BN 的天然气管输管道燃气轮机故障预警方法研究

王明达¹ 韦永健¹ 王建军¹ 陈子新¹ 许志倩¹ 闫春颖²

1. 中国石油大学机电学院 2. 中国石油管道联合有限公司西部分公司

摘 要 燃气轮机是天然气管输管道的核心动力设备, 由于其结构复杂、零部件众多、工作负荷大, 在运行过程中常发生故障并触发自保护停机, 影响了主管线输气的稳定性。为此, 针对天然气干线管道燃气轮机及其附属设备的关键部件、关键故障, 利用 SCADA 系统的在线数据, 对故障数据进行分析, 建立基于支持向量机的在线异常预测模型和基于贝叶斯网络的故障诊断模型; 然后通过引入偏离度建立了上述两种模型相结合的故障预警模型, 并在天然气干线管道燃气轮机机组上进行了验证。结果表明: ①所建立的基于支持向量机的预测模型具有较强的泛化能力, 能对压力状态做出较为准确的预测, 但是随着预测时间的变长, 预测精度也会不断降低; ②通过关注故障诊断模型中各底事件的发生概率, 能够为现场维护人员提供优先检查的依据, 进而减少设备非计划外停机事故的发生; ③在燃气轮机润滑油系统实际发生的故障场景进行的应用与验证结果表明, 该模型可以准确地对系统故障提前预测并定位, 方法可行、有效, 有较高的应用价值。

关键词 天然气 长输管道 燃气轮机 支持向量机 贝叶斯网络 故障树 故障预警与定位

DOI: 10.3787/j.issn.1000-0976.2017.11.015

A SVM-BN based early warning method for gas turbines of natural gas long-distance pipelines

Wang Mingda¹, Wei Yongjian¹, Wang Jianjun¹, Chen Zixin¹, Xu Zhiqian¹ & Yan Chunying²

(1. College of Mechanical and Electronic Engineering, China University of Petroleum, Qingdao, Shandong 266580, China; 2. Western Branch, China Petroleum Pipeline Joint Ltd., Urumqi, Xinjiang 735000, China)

NATUR. GAS IND. VOLUME 37, ISSUE 11, pp.112-118, 11/25/2017. (ISSN 1000-0976; In Chinese)

Abstract: A gas turbine is the core power equipment for long-distance natural gas pipelines. And because of its complex structure, many parts and heavy work load, it often fails and triggers self-protection shut down during the operation, and consequently impacts the gas transmission stability of the main pipelines. In this paper, the fault data were analyzed using the online data of SCADA system (supervisory control and data acquisition) from the aspects of gas turbines in the main pipelines and its support key parts and key faults. Then, an online anomaly prediction model based on the support vector machine (SVM) and a fault diagnosis model based on Bayesian network (BN) were established. Finally, a fault early warning model combining the above two models was established by introducing the degree of deviation, and verified at the gas turbine units of main natural gas pipelines. It is demonstrated that the SVM based prediction model is of strong generalization, and can provide accurate prediction on the pressures state, but its prediction precision will decrease continuously as the prediction goes on. Besides, it can provide the on-site maintainers with the basis of preferential check by analyzing the probability of all bottom events in the fault diagnosis model, so as to decrease nonscheduled shut down accidents of equipments. Finally, the SVM-BN based model is applied to the actual fault of a lubrication oil system of a gas turbine. And it is verified that this model can provide advanced prediction and positioning on the faults accurately, so it is feasible, efficient and practical.

Keywords: Natural gas; Long-distance pipeline; Gas Turbine; Support vector machine (SVM); Bayesian network (BN); Fault Tree; Fault early warning and positioning

基金项目: 国家自然科学基金项目“管道泄漏检测中的退化多源信息融合模型研究”(编号: 51204203)。

作者简介: 王明达, 1984 年生, 讲师, 博士; 主要从事油气设备安全检测与监测方面的研究工作。地址: (266580) 山东省青岛市黄岛区长江西路 66 号中国石油大学(华东)机电学院。ORCID: 0000-0001-9608-5333。E-mail: wangmd@upc.edu.cn

截至 2015 年底,我国已建成油气管道 12×10^4 km,其中天然气管道 7.6×10^4 km,目前已基本形成覆盖西北、东北、西南和沿海方向的输气通道,成为推动中国经济发展和保障民生的能源动脉。天然气主管线动力机组多采用燃气轮机和离心式压缩机的组合形式,然而,部分管道运行多年,其动力机组逐渐进入故障多发期,每年的故障次数不断增加^[1-2]。常规的机械振动故障诊断方法应用广泛,但是信号源单一(振动信号),能分析的故障类型有限,通常只能诊断出动设备本体的机械故障,无法诊断复杂机组系统的故障(如机组辅助设备故障)。目前,数据采集与监控(Supervisory Control and Data Acquisition, SCADA)系统在复杂设备系统应用广泛,其含有多种工艺参数,蕴含了大量有价值的信息。研究发现,大多数设备故障发生前都有很多 SCADA 系统工艺参数上的征兆且可被预测^[3]。因此,利用 SCADA 系统的实时数据开展设备故障预警方法研究,可提前对设备进行维护,对提高设备运行的安全性、经济性具有重要意义。

目前,国内外对复杂设备故障预警方法研究很少,大多采用传统的故障诊断方法^[4]。首先获取振动、噪声和温度等信号源;然后传输、存取信号;其次对存取的信号降噪并提取信号特征;最后对提取的信号进行识别,通过分析给出故障的处理方法。传统的故障诊断方法中最为常用的是振动诊断技术和油液分析技术^[2-4]。振动诊断技术涉及信息传感、振动测试、信号处理等诸多领域,因而对设备诊断技术人员的要求较高。此外,该技术的另一个特点是部位敏感性。油液分析技术只对磨损类故障有效,诊断周期长,而且一般还只能在实验室进行,诊断结果受操作人员的影响大。由于 SCADA 系统在复杂设备的广泛应用,其监测范围从单一的振动参数扩展到现在的压力、温度、流量以及其他各种工艺状态参数,随着状态监测与故障诊断系统功能和性能的提高,SCADA 系统由原来单纯的状态监测渐渐向状态监测、状态趋势预测和故障预警的集成方面过渡。

笔者以天然气干线管道燃气轮机及其附属设备为研究对象,针对其关键部件和关键故障,利用 SCADA 系统的在线数据,开展实时故障预警方法研究。首先对故障数据进行分析,建立基于支持向量机的预测模型,预测出系统可能出现的异常状态;然后建立贝叶斯网络诊断模型,计算出现异常状态时系统各元件发生故障的概率,对故障元件进行定位;最后应用现场真实故障验证模型的有效性。

1 基本理论方法分析

故障预警模型的建立总体上分为两大步骤:①建立系统工艺参数的预测模型;②预测出工艺参数异常后,对系统的故障进行诊断。其中,第一步用到了支持向量机的方法,第二步应用了贝叶斯网络推理的方法。下面对这两个基本方法进行简单介绍。

1.1 支持向量机

支持向量机(Support Vector Machine, SVM)是近年来发展起来的一种机器学习方法,被广泛应用于解决分类和回归问题中,当其被应用到回归预测问题中时可被称为支持向量回归机(Support Vector Regression Machine, SVR)^[5-8]。该方法建立在统计学习理论和结构风险最小化的基础之上,通过保持经验风险值一定、置信范围最小化来实现结构风险最小化,能够较好地解决小样本的学习问题。SVM 的基本原理是对给定的训练样本集 $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset R^n \times R$, 通过非线性映射 ϕ 把数据映射到高维特征空间,在高维特征空间中进行分类运算,得到一个能将训练样本分开且误差最小的最优分类面。从理论上说,支持向量机得到的是全局最优点,从而避免了神经网络方法的局部极值问题。故障发生本身属于小概率事件,样本一般较少,这是支持向量机用于故障预测领域的突出优势所在。

1.2 贝叶斯网络

贝叶斯网络(Bayesian Network, BN)是采用有向图来描述概率关系的理论,具有前向和后向的概率推理计算能力。前向推理可以进行系统的可靠性评价,后向推理可以通过证据的输入进行系统的故障诊断^[9-10]。建立一个能得出有意义结果的 BN 取决于节点之间的合理连接与概率分布^[11]。BN 是具有若干节点的有向无环图,其中节点代表随机变量,有向弧反映变量间的依赖关系,变量间依赖关系的强度由节点与其父节点的条件概率表(Conditional Probability Table, CPT)来表示。一个简单的 BN 图如图 1 所示。




图 1 贝叶斯网络图

BN 是建立在条件独立的假设上, BN 中的一组变量 $U = A(A_1, A_2, A_3, \dots, A_n)$, 利用条件独立性进行分解, 可将联合概率 $P(U)$ 分解为如下形式^[12]:

$$P(U) = \prod_{i=1}^n P(A_i | A_1, A_2, \dots, A_{n-1}) = \prod_{i=1}^n P[A_i | \text{parent}(A_i)] \quad (1)$$

式中 $P(U)$ 表示网络的联合概率分布; P 表示某变量的概率; $\text{parent}(A_i)$ 表示节点 A_i 的父节点。

BN 的一个优点是概率更新。在 BN 中某些变量的证据确定后, 证据的影响沿着网络传播, 传播中相邻网络的先验概率得到更新, 得到变量的后验概率。以图 1 中 D 、 C 节点为例, 得到式 (2)^[13], 即

$$P(C|D) = \frac{P(D|C)P(C)}{P(D)} \quad (2)$$

2 故障预警模型建立的方法

故障预警模型的建立分为实时预测和故障诊断两个部分, 故障诊断的核心为贝叶斯网络, 其计算具有一定的复杂性, 为了保障预警系统的运行稳定性, 可通过触发机制来使其运行 (图 2)。




图 2 故障预警方法实施流程图

首先是基于 SVM 的设备状态实时预测, 即 SCADA 系统在检测过程中, 间歇性地抽取其中部分数据并对其后一段时间的发展状态进行预测, 根据偏离度的大小判断是否处于异常状态。其次是基于 BN 的故障诊断, 即预测工艺参数异常后系统的运行情况, 揭示哪些零部件的故障导致工艺参数的异常, 并根据这些零部件的发生概率, 为现场操作人员对设

备的提前维护提供依据, 有效减少设备故障发生率。

2.1 基于 SVM 的设备状态实时预测

2.1.1 分析 SCADA 系统蕴含各数据项的特点

工艺参数包括温度、压力、流量和电力等, 从数据属性来说, 并不是所有的数据都适合预测, 从实用性上来说, 也并不是所有的数据都需要预测, 选择对潜在故障的发展有明显指示性的数据项进行预测研究。

2.1.2 基于 SVM 预测模型的建立

首先采集原始数据, 把原始数据进行归一化处理, 得到训练数据和测试数据。然后选择 SVM 核函数, 选取不同的核函数可以得到不同的 SVM 模型, 常用的核函数有线性核函数、径向核函数和 Sigmoid 核函数。最后选取 SVM 参数, 在 SVM 的训练过程中, 有一种交叉验证的方法, 把训练集分成 N 份, 每次把其中 1 份当作是测试集, 同时用剩余几份训练分类模型, 并迭代这个过程, 求出测试集分类效果最好时的参数 c 和 g ^[14]。基于 SVM 的预测流程如图 3 所示。




图 3 基于 SVM 的预测流程图

2.1.3 计算各参数偏离度

对现场 SCADA 系统采集的数据预测以后, 用下列方法实时计算系统所处的状态。

基于模糊理论评估设备所处的状态, 用“偏离度”来描述各参数的预测值与设计值 (或正常值) 之间偏离的程度^[15]。偏离度的计算公式如下:

$$r = \frac{2(d-s)}{a_{\max}^h - a_{\min}^l} \times 100\% \quad (3)$$

式中 r 表示偏离度; d 表示测量参数值; s 表示标准参数值; $a_{\max}^h$ 表示高报警最大值; $a_{\min}^l$ 表示低报警最小值。

偏离度绝对值为 $0 \sim 30\%$ 时, 表示参数稳定, 没有发生故障的可能性; 偏离度绝对值为 $30\% \sim 100\%$ (超过 100% 按 100% 判定) 时, 表示过程参数发生较大变化, 系统处于危险状态; 偏离度与设备状态评价对应关系如表 1 所示。

表 1 偏离度与状态评价关系表

偏离度	状态评价
30% ~ 100%	高
0 ~ 30%	正常
0 ~ -30%	正常
-30% ~ -100%	低

2.2 基于 BN 的故障诊断

基于 BN 的故障诊断流程如下。

1) 基于 BN 推理模型的建立。结合历史数据库、SCADA 系统监测的工艺参数类型以及事故案例库建立系统的故障树模型。将故障树模型中各节点映射到 BN 节点, 如果故障树模型中有多个相同的节点, 只需要构造 1 个节点映射到 BN 模型中; 故障树化的 BN 中节点 $M_i(i = 1, \dots)$ 的条件概率根据故障树中逻辑门关系给出^[12,16]。

2) 进行异常状态的预警。把预测模型中的异常状态输入到 BN 模型中, 进而更新整个网络。如燃气轮机润滑油系统的温度过高, SVM 预测模型可从之前数据中提取出的特征值预测出此异常状态, 并转化为偏离度的形式, 那么 BN 就会将此证据加载到网络中, 然后, 证据就会在整个网络中传播, 进而确定出可能会发生故障的零部件, 故可对其进行提前维护。

3 燃气轮机机组故障预警建模

图 4 为某燃气轮机润滑油系统的工艺流程图。该系统主要由供油泵、回油泵、过滤器、分离器、供应总阀(ZSL-1)和温度控制阀(TCV-1)等组成, 为燃气发生器的轴承提供冷却润滑油, 并且为 VSV 执行机构提供液压油。

由图 4 可知, 该润滑油泵增压吸油, 经双联油滤分为 4 路进入附件变速箱、传动变速箱和 B 油箱、C 油箱, 其中, 附件变速箱前连接油气分离器, 4 路润滑油汇合后流回油箱。

3.1 润滑油系统工艺参数分析

润滑油系统中分布着传感器以测量各零部件的工艺参数, 利用 SCADA 系统所获取的机组数据项多、数据类型复杂, 需要分析各数据项的特点, 分析结果如表 2 所示。

3.2 润滑油系统预测模型的建立

采集天然气干线管道燃气轮机机组润滑油系统某 3 个月的数据, 首先采用 Matlab 软件对这些数据进行归一化处理, 选出前 2 个月的数据作为训练样本, 后 1 个月的数据为测试样本。然后选择核函数为径向核函数, 其包括 2 个模型参数(c, g)和一个核参数(σ^2), 用训练样本对这些参数进行优化选取。最后, 用测试样本对其进行测试, 如果准确就得到系统预测模型, 如果不准确则返回继续优化各参数。




图 4 润滑油系统工艺流程图

注：图中 P、T、F 分别表示压力指示变送器、温度指示变送器和流量指示变送器

表 2 机组工艺参数分析结果表

参数	数据采集项目	预测类型	基准数值	报警阈值
温度 /℃	冷却器入口处温度	短期预测	110.0	-6.7 ~ 171.0
	冷却器出口处温度	短期预测	60.0	-6.7 ~ 93.3
	双联油滤入口 / 出口压力	短期预测	0.620	0.350 ~ 1.370
压力 /MPa	泵 PS1/2/3/4 入口压力	短期预测	0.140	0.103 ~ 0.172
	泵 PS1/2/3/4 出口压力	短期预测	0.400	0.200 ~ 0.760
	电机电流	无法预测	/	/
开关	系统运行状态	无法预测	/	/
	系统驱动端泄漏	无法预测	/	/
流量 / (L·min ⁻¹)	某管道处流量	短期预测	13	5 ~ 22

3.3 润滑油系统故障诊断模型的建立

3.3.1 润滑油系统故障树模型的建立

对润滑油系统工艺及历史事故案例库进行分析，以工艺参数温度、压力和流量的异常为中间事件，影响各工艺参数异常的因素为底事件，建立故障树模型（图 5）。

3.3.2 BN 推理模型的建立

通过故障树模型得出影响润滑油系统故障的因素，在此基础上把故障树节点映射到 BN 模型中。其中，把节点 8、9 合并为 F8，节点 12、13 合并为 F12 映射到 BN 中。利用 BN 软件 GeNIe 绘制润滑油系统 BN 故障诊断模型（图 6）。

对于 BN 节点的条件概率，以节点“润滑油温度低”、节点 F5 和节点 F6 为例，节点“滑油温度低”、节点 F5 和节点 F6 有“成功”和“失败”两种状态。依据故障树的逻辑门关系，F5 和 F6 只要有一个发生就会导致润滑油温度低，其关系用 CPT 描述（表 3）。




图 5 润滑油系统故障树模型图




图 6 BN 故障诊断模型图

表 3 逻辑门与条件概率对应关系表

F5 状态	F6 状态	润滑油温度低	
		成功	失败
成功	成功	1	0
成功	失败	0	1
失败	成功	0	1
失败	失败	0	1

但是，在设备实际运行过程中，即使 F5 和 F6 都发生也可能不会导致润滑油温度低，也有可能 F5 和 F6 都不发生，但是润滑油温度仍变低。所以应该根据

专家和历史数据对表 3 所示的关系进行修正, 结果如表 4 所示。

表 4 修正后的条件概率表			
F5 状态	F6 状态	润滑油温度低	
		成功	失败
成功	成功	0.96	0.04
成功	失败	0.08	0.92
失败	成功	0.08	0.92
失败	失败	0.02	0.98

4 燃气轮机机组润滑油系统事故案例分析

2015 年 3 月 16 日某一时刻, 某天然气干线管道燃气轮机机组润滑油系统由于供应总阀故障导致润滑油汇管压力降低, 进而导致连锁停机。根据前述方法, 结合该实际案例具体数据, 对该方法的应用有效性进行验证。通过前文建立的预测模型和故障诊断模型进行分析。

4.1 工艺参数异常预测

取事故发生前油泵 PL-1 出口处的部分数据加载到润滑油系统预测模型中, 预测效果如图 7 所示。




图 7 预测效果图

由图 7 可知, 所建立的基于支持向量机的预测模型具有较强的泛化能力, 能对压力状态做出较为准确的预测, 但是随着预测时间的变长预测精度会不断降低。

图 7 红色虚线表示压力异常触发线, 由图 7 可知在 t_1 时刻压力参数出现异常, 并由式 (3) 及表 2 可知, 从 t_1 时刻起其偏离度在 $-30\% \sim -100\%$ 之间变动。因此, 系统判定此参量发生了低偏差, 系统

自动触发故障诊断模型。

4.2 工艺参数异常状态的诊断

把上述的状态评价输入到 BN 故障诊断模型中节点“润滑油压力低”的低状态作为证据, 更新整个贝叶斯网络后, 得到各部件的后验概率分布 (表 5)。

表 5 各节点的含义及后验概率表				
编号	含义	先验概率	后验概率	差值
F1	冷却器泄漏	0.32%	0.34%	0.02%
F2	冷却器结垢	1.63%	1.68%	0.05%
F3	冷却器进水温度高	1.55%	1.59%	0.04%
F4	油气分离器温度高	2.14%	2.29%	0.15%
F5	温度控制器失效	2.31%	2.43%	0.12%
F6	冷却水温度过低	0.93%	1.32%	0.39%
F7	管路堵塞	1.83%	1.93%	0.10%
F8	供应总阀故障	1.60%	6.65%	5.05%
F10	冷却器故障	0.50%	2.73%	2.23%
F11	滤芯堵塞	0.41%	0.93%	0.52%
F12	油泵故障	0.15%	0.55%	0.40%
F14	管路漏油	0.90%	2.80%	1.70%
F15	油温过高汽化	0.79%	1.13%	0.34%

注：先验概率数据来源于“西气东输”管道新疆段机组故障资料库

由表 5 可知, 当节点“润滑油压力低”状态更新时, 贝叶斯网络模型中底事件节点的状态也发生了改变, 其中节点 F8 (供应总阀故障) 发生的概率最大及其概率的变化也最大, 这说明节点 F8 在所有底事件中发生故障的可能性最大。其原因可能是供应总阀自身故障和人的因素等使供应总阀处于半关或全关状态, 从而导致压力降低。其次, 节点 F10 (冷却器故障) 概率变化明显以及节点 F14 (管路漏油) 发生概率较大, 说明这两个部分对润滑油系统压力的降低有较大的影响, 也应该对其进行检查、维护。

经上述分析, 通过对工艺参数的预测及对工艺参数异常状态的诊断, 能较准确地定位到故障发生的根源 (节点 F8), 这验证了该预警方法的合理性。其次, 通过关注故障诊断模型中各底事件的发生概率, 能够为现场维护人员提供优先检查的依据, 进而减少燃气轮机非计划外停机事故的发生。

5 结论

1) 分别建立基于 SVM 的预测模型和基于 BN

的故障诊断模型,通过引入偏离度这一概念把两者结合起来建立了触发式的故障预警模型。

2) 案例分析中通过将燃气轮机润滑油系统实际发生的故障作为研究对象,进行应用与验证,结果表明该方法可以准确地对系统故障提前预测并定位,方法可行、有效,具有较高的应用价值。

参 考 文 献

- [1] 王伟影,赵宁波,唐瑞,李淑英,胡清华. 燃气轮机排气温度异常检测及诊断[J]. 哈尔滨工程大学学报, 2015, 36(3): 337-342.
Wang Weiying, Zhao Ningbo, Tang Rui, Li Shuying & Hu Qinghua. Anomaly detection and diagnosis of gas turbine exhaust gas temperature[J]. Journal of Harbin Engineering University, 2015, 36(3): 337-342.
- [2] 衣爽. 燃气轮机滑油和燃料系统故障诊断与预测研究[D]. 哈尔滨: 哈尔滨工程大学, 2012.
Yi Shuang. Research on fault diagnosis and prediction of gas turbine lube oil and fuel system[D]. Harbin: Harbin Engineering University, 2012.
- [3] 梁颖,方瑞明. 基于 SCADA 和支持向量回归的风电机组状态在线评估方法[J]. 电力系统自动化, 2013, 37(14): 7-12.
Liang Ying & Fang Ruiming. An online wind turbine condition assessment method based on SCADA and support vector regression[J]. Automation of Electric Power Systems, 2013, 37(14): 7-12.
- [4] 苑津莎,张英慧,牛丽仙,刘献伟. 基于 SOFM 和支持向量机回归的短期负荷预测方法[J]. 电力科学与工程, 2009, 25(8): 27-29.
Yuan Jinsha, Zhang Yinghui, Niu Lixian & Liu Xianwei. Short-term load forecasting method based on SOFM and SVR[J]. Electric Power Science and Engineering, 2009, 25(8): 27-29.
- [5] 邱晗. 基于故障树和油液检测的柴油机的故障诊断与研究[D]. 大连: 大连海事大学, 2010.
Qiu Han. Study on diesel engine fault diagnosis technology based on fault tree analysis and oil detection[D]. Dalian: Dalian Maritime University, 2010.
- [6] Najafzadeh M, Etemad-Shahidi A & Lim SY. Scour prediction in long contractions using ANFIS and SVM[J]. Ocean Engineering, 2016, 111: 128-135.
- [7] 常甜甜. 支持向量机学习算法若干问题的研究[D]. 西安: 西安电子科技大学, 2010.
Chang Tiantian. Research on some problems of support vector machine learning algorithm[D]. Xi'an: Xidian University, 2010.
- [8] 姚凯丰,陆文凯,丁文龙,张善文,肖焕钦,李衍达. 一种基于 SVM 特征选择的油气预测方法[J]. 天然气工业, 2004, 24(7): 36-38.
Yao Kaifeng, Lu Wenkai, Ding Wenlong, Zhang Shanwen, Xiao Huanqin & Li Yanda. Hydrocarbon prediction method based on SVM feature selection[J]. Natural Gas Industry, 2004, 24(7): 36-38.
- [9] 刘林林,任羿,王自力,杨德真. 基于贝叶斯网络的 GO 法模型算法[J]. 系统工程与电子技术, 2015, 37(1): 212-218.
Liu Linlin, Ren Yi, Wang Zili & Yang Dezhen. Algorithm based on Bayesian networks for GO methodology[J]. Systems Engineering and Electronics, 2015, 37(1): 212-218.
- [10] 张剑飞. 贝叶斯网络学习方法和算法研究[D]. 长春: 东北师范大学, 2005.
Zhang Jianfei. The study of the method and arithmetic of learning Bayesian networks[D]. Changchun: Northeast Normal University, 2005.
- [11] Matellini DB, Wall AD, Jenkinson ID, Wang J & Pritchard R. Modelling dwelling fire development and occupancy escape using Bayesian network[J]. Reliability Engineering & System Safety, 2013, 114: 75-91.
- [12] 孙旋,牛秦洲,徐和飞,巫世晶,秦明,黄河潮. 基于贝叶斯网络的人因可靠性评价[J]. 中国安全科学学报, 2006, 16(8): 22-27.
Sun Xuan, Niu Qinzhou, Xu Hefei, Wu Shijing, Qin Ming & Huang Hechao. Human reliability assessment based on Bayesian networks[J]. China Safety Science Journal, 2006, 16(8): 22-27.
- [13] 张歆炀,帕孜来·马合木提. 基于故障树与键合图的贝叶斯网络故障诊断[J]. 电测与仪表, 2016, 53(2): 21-26.
Zhang Xinyang & Pazilai Mahemuti. Fault diagnosis for Bayesian network based on fault tree and bond graph[J]. Electrical Measurement & Instrumentation, 2016, 53(2): 21-26.
- [14] Zhu Anmin & Yi Xin. The comparisons of four methods for financial forecast[C]//Proceedings of 2012 IEEE International Conference on Automation and Logistics, 15-17 August 2012, Zhengzhou, China. DOI: <http://dx.doi.org/10.1109/ICAL.2012.6308168>.
- [15] 胡瑾秋,张来斌,王安琪. 炼化装置故障链式效应定量安全预警方法[J]. 化工学报, 2016, 67(7): 3091-3100.
Hu Jinqiu, Zhang Laibin & Wang Anqi. Quantitative safety early warning method of fault propagation for petrochemical plants[J]. CIESC Journal, 2016, 67(7): 3091-3100.
- [16] 许伟,程刚,陈于涛,曾凡明,李睿. 舰船柴油主机润滑油系统贝叶斯网络推理故障诊断方法[J]. 四川兵工学报, 2015, 36(3): 86-90.
Xu Wei, Cheng Gang, Chen Yutao, Zeng Fanming & Li Rui. Method for fault diagnosis of Bayesian network inference in marine lube oil system[J]. Journal of Sichuan Ordnance, 2015, 36(3): 86-90.

(修改回稿日期 2017-09-30 编辑 何明)