

DOI: 10.7652/xjtuxb201808002

一种采用贝叶斯网络的制造过程异常诊断方法

石文栋, 陈富民, 屈发明, 张瑞, 吕春雷
(西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对制造过程异常原因复杂、基于传统控制图诊断分析困难等问题,提出了一种采用贝叶斯网络的制造过程异常诊断方法。利用过程异常诊断的先验知识,结合需要诊断的异常特征,构建基于贝叶斯网络的制造过程异常诊断模型。首先提取控制图异常征兆特征,建立贝叶斯网络的异常征兆节点和异常原因节点并进行关联;然后利用先验知识确定贝叶斯网络中的先验概率,建立贝叶斯网络诊断模型;最后根据控制图异常特征,利用诊断模型推理异常发生的原因。以汽轮机转子叶轮制造为例进行了诊断,验证了采用贝叶斯网络作为制造过程诊断方法的可行性。

关键词: 制造过程;异常特征;贝叶斯网络;诊断模型

中图分类号: TH16 **文献标志码:** A **文章编号:** 0253-987X(2018)08-0009-06

Abnormality Diagnosis Method for Manufacturing Process Based on Bayesian Network

SHI Wendong, CHEN Fumin, QU Faming, ZHANG Rui, LÜ Chunlei
(State Key Laboratory for Manufacturing System Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Based on Bayesian network, a new method was proposed to diagnose manufacturing process abnormalities, which may be caused by multiple complex reasons. Using the prior knowledge of historical process abnormality diagnosis results, in combination with the abnormal characteristics of present process, the Bayesian network was constructed and the characteristics of the abnormal symptom of the control chart were extracted, the abnormal symptom nodes and the abnormal reason nodes of the Bayesian network were established and correlated. Then the prior distribution in Bayesian network was determined by prior knowledge, and the Bayesian network diagnosis model was determined. According to the abnormal characteristics of the control chart, the reason why the abnormality occurs was diagnosed with the proposed diagnostic model. A turbine impeller manufacturing process was diagnosed, and result validates the feasibility of the proposed method.

Keywords: manufacturing process; abnormal characteristics; Bayesian network; diagnosis model

统计过程控制(SPC)技术作为制造过程质量控制的重要手段,可以有效地监控制造过程统计异常并提出预警,已经广泛应用于产品制造过程中^[1]。但是,SPC控制图没有提供和分析引起质量波动的原因,因影响制造过程质量波动的原因很多,

包括人、机、料、法、测、环等,很难依据控制图做出准确全面的判断,推断异常发生的原因。因此,需要建立制造过程异常诊断模型,快速准确地诊断制造过程异常原因。

张公绪等提出的两种质量诊断理论,成功诊断

出电子生产线中导致加工质量异常的工序,开辟了制造过程统计异常诊断的方向^[2],卓德保与徐济超针对过程质量诊断进行了系统的综述^[3]。基于解析模型和基于信号的过程诊断方法是出现比较早的过程诊断方法^[4]。基于解析模型,如状态空间法^[5]等,由于制造过程复杂多变,构造精确的解析模型难度大,方法使用受到极大限制;基于信号模型,如傅里叶变换、相关函数等,从统计过程的输出数据提取诸如方差、相位等信息,确定过程异常的原因,但这类方法往往包含复杂统计计算和分析过程。随着人工智能技术的发展,将统计过程控制技术和人工智能技术相结合的基于知识推理的诊断方法得到广泛的关注,成为当前过程质量诊断方法研究的热点^[6]。目前,制造工程异常诊断方法中采用较为广泛的人工智能技术主要有:基于人工神经网络^[7-8]、支持向量机(SVM)^[9-10]、决策树^[11]等。

贝叶斯网络作为一种人工智能技术,是不确定知识表达和推理领域最有效的理论之一,可用于解决预测、智能推理、诊断、决策、风险评估、可靠性分析等方面的问题^[12-13]。目前,贝叶斯网络在诊断方面已经应用于多个领域,如电力系统^[14-15]、机器设备^[16-17]等。利用贝叶斯网络在诊断领域的优势,针对制造过程统计异常的随机及不确定性等特点,本文运用贝叶斯网络推理方法,对制造过程异常原因进行诊断。在统计异常诊断过程中,提取控制图异常征兆特征,建立贝叶斯网络异常征兆节点和异常原因节点,构造控制图异常推理贝叶斯网络结构图,利用先验知识建立贝叶斯网络推理概率表。以汽轮机转子叶轮制造过程诊断为例,验证分析了基于贝叶斯网络的统计异常原因推理过程。结果表明,本文方法可以有效地诊断出引起制造过程质量波动的异常原因,并且大大提高了诊断效率。

1 贝叶斯网络基本理论

贝叶斯网络又称信念网络^[18],一个典型的贝叶斯网络由两部分组成:①有向无环图 G ,其中每一个节点代表一个变量,节点之间的有向弧段反应变量间的依赖关系,指向节点 V 的所有节点称为 V 的父节点,图1为一个简单的贝叶斯网络拓扑结构;②条件概率集 P 表示每个节点相对于父节点的所有可能发生的条件概率。

贝叶斯网络规定以节点 V_i 的父节点为条件, V_i 与任意非 V_i 子节点条件独立,则有 n 个节点的贝叶斯网络的联合概率分布为

$$P(V_1, V_2, \dots, V_n) = \prod_{i=1}^n P(V_i | \pi(V_i))$$

式中: $\pi(V_i)$ 是贝叶斯网络中 V_i 父节点集合 $\Pi(V_i)$ 中的变量取值后的一个组合,若 V_i 没有父节点,则集合 $\Pi(V_i)$ 为空,即 $P(V_i | \pi(V_i)) = P(V_i)$ 。

贝叶斯网络推理是基于先验知识,由贝叶斯网络结构计算所需事件的概率。按照推理方向贝叶斯网络推理主要分为3种:后验概率问题、最大后验假设问题以及最大可能解释问题。制造过程异常诊断属于后验概率问题,即在已知结论的前提下,推断引起该结论发生的原因。




图1 贝叶斯网络结构示意图

2 诊断模型

2.1 制造过程异常特征提取

SPC控制图监控制造过程判别异常的基本方法是根据判异准则,如果发生小概率事件就判定制造过程异常。假设统计过程控制系统采用了 m 项判异准则,各准则分别用 $R_1, R_2, \dots, R_m$ 表示。国标GB/T4091—2001规定了常规控制图主要有8种判异准则,此外本文将“数据超出规范线”也列入在判异准则之中,用符号 R_0 表示,这样所有的准则集合为 $R = \{R_0, R_1, R_2, \dots, R_m\}$ 。

当前控制图状态可以用3个变量来描述:数据点趋势、均值趋势、方差趋势。

数据点趋势(T_d):如果控制图没有违背任何准则,则 $T_d = \Phi$,否则 $T_d = \bigcup_{i=1}^k R_i$, k 为控制图异常发生时违背的准则个数。本文简化处理,只考虑违背1个准则的情况,即 $T_d = R_i$,如果违背了多个准则,则取危害性最为严重的准则,判异准则的危害性按照“超出规格线>超出控制线>数据点趋势异常”顺序确定。

均值的趋势(T_x):大于期望值($\bar{X} > \mu + \sigma$)、小于期望值($\bar{X} < \mu - \sigma$)和正常情况($|\bar{X} - \mu| \leq \sigma$),这里的 μ, σ 分别为当前质量特性期望和总体方差, $\bar{X}$ 为最近一批数据的平均值。

方差的趋势(T_s):大于总体方差($\frac{S}{\sigma}>2$)、小于总体方差($\frac{S}{\sigma}<\frac{1}{2}$)和正常情况($\frac{1}{2}\leq\frac{S}{\sigma}\leq 2$), S 为最近一批数据的方差。

失控点数据(T_v): $|x-\mu|\leq\sigma$ 、 $\sigma<x-\mu\leq 3\sigma$ 、 $-\sigma>x-\mu\geq 3\sigma$ 、 $x-\mu>3\sigma$ 、 $x-\mu<-3\sigma$ 共 5 种情况。

2.2 建立贝叶斯网络节点

以汽轮机转子叶轮直径制造过程监控为例,建立贝叶斯网络节点。叶轮直径制造过程监控采取全检方式,5 组数据作为一个数据点,均值-标准差控制图如图 2 所示。如果控制图发生异常,对控制图异常特征进行提取,包括将控制图数据趋势和方差作为异常节点,如表 1 所示。造成叶轮直径控制图异常的原因很多,根据生产经验,本文选取人、设备、原材料、工艺方法、品质检验、生产环境 6 个方面作

为系统的异常原因,并和异常节点进行关联,如表 2 所示。因此,建立的贝叶斯网络结构如图 3 所示。




图 2 汽轮机转子叶轮直径均值-标准差控制图

表 1 异常征兆节点列表

符号	征兆内容	取值
R_0	数据超出规范线	T,F(表示是,否)
R_1	1 个点出界	T,F(表示是,否)
R_2	连续 9 个点落在中心线同一侧	T,F(表示是,否)
R_3	连续 6 个点递增或者递减	T,F(表示是,否)
R_4	连续点 14 中相邻点交替上下	T,F(表示是,否)
R_5	连续 3 点中有 2 点落在中心线同一侧的 2σ 区以外	T,F(表示是,否)
R_6	连续 5 点中有 3 点落在中心线同一侧的 σ 区以外	T,F(表示是,否)
R_7	连续 15 点落在中心线两侧的 σ 区内	T,F(表示是,否)
R_8	连续 8 点落在中心线两侧且无一在 σ 区内	T,F(表示是,否)
S	方差	U,C,L(表示大,中,小)

表 2 系统异常原因列表

异常原因	符号	关联的征兆
加工误操作	C_1	R_0 、 R_1 、 R_2 、 R_3 、 S
操作不熟练	C_2	R_1 、 R_3 、 R_8 、 S
设备故障	C_3	R_0 、 R_1 、 R_3 、 R_4 、 S
刀具磨损	C_4	R_5 、 R_6 、 S
数据作弊	C_5	R_7 、 R_8 、 S
量仪精度低	C_6	R_2 、 R_8 、 S
夹具安装错误	C_7	R_5 、 R_6 、 S
设备振动厉害	C_8	R_4 、 R_5 、 R_6 、 S

2.3 建立贝叶斯网络结构概率表

贝叶斯网络的概率表反映了节点变量间的相互依赖关系,是基于控制图进行异常诊断的知识的总




图 3 控制图异常推理贝叶斯网络图

结,一方面可以来源于人们对事物的先验认识,另一方面从历史诊断信息中获得。采用贝叶斯网络的学习方法可以不断修正完善这些概率知识。下面,列出了各节点在父节点下概率取值(见表 3~表 5),以此作为贝叶斯网络推理的先验知识。

表 3 控制图数据趋势异常诊断网络概率表

判据	符号	先验概率
是否违背准则 R_0	R_0	$P(R_0 C_1,C_3)=0.90; P(R_0 C_1,\bar{C}_3)=0.65$ $P(R_0 \bar{C}_1,C_3)=0.60; P(R_0 \bar{C}_1,\bar{C}_3)=0.20$
是否违背准则 R_1	R_1	$P(R_1 C_1,C_2,C_3)=0.90; P(R_1 C_1,C_2,\bar{C}_3)=0.60$ $P(R_1 C_1,\bar{C}_2,C_3)=0.75; P(R_1 C_1,\bar{C}_2,\bar{C}_3)=0.40$ $P(R_1 \bar{C}_1,C_2,C_3)=0.75; P(R_1 \bar{C}_1,C_2,\bar{C}_3)=0.25$ $P(R_1 \bar{C}_1,\bar{C}_2,C_3)=0.35; P(R_1 \bar{C}_1,\bar{C}_2,\bar{C}_3)=0.10$
是否违背准则 R_2	R_2	$P(R_2 C_1,C_6)=0.95; P(R_2 C_1,\bar{C}_6)=0.75$ $P(R_2 \bar{C}_1,C_6)=0.70; P(R_2 \bar{C}_1,\bar{C}_6)=0.20$
是否违背准则 R_3	R_3	$P(R_3 C_1,C_2,C_3)=0.90; P(R_3 C_1,C_2,\bar{C}_3)=0.50$ $P(R_3 C_1,\bar{C}_2,C_3)=0.80; P(R_3 C_1,\bar{C}_2,\bar{C}_3)=0.35$ $P(R_3 \bar{C}_1,C_2,C_3)=0.85; P(R_3 \bar{C}_1,C_2,\bar{C}_3)=0.30$ $P(R_3 \bar{C}_1,\bar{C}_2,C_3)=0.65; P(R_3 \bar{C}_1,\bar{C}_2,\bar{C}_3)=0.10$
是否违背准则 R_4	R_4	$P(R_4 C_3,C_8)=0.90; P(R_4 C_3,\bar{C}_8)=0.70$ $P(R_4 \bar{C}_3,C_8)=0.55; P(R_4 \bar{C}_3,\bar{C}_8)=0.15$
是否违背准则 R_5	R_5	$P(R_5 C_4,C_7,C_8)=0.80; P(R_5 C_4,C_7,\bar{C}_8)=0.65$ $P(R_5 C_4,\bar{C}_7,C_8)=0.60; P(R_5 C_4,\bar{C}_7,\bar{C}_8)=0.55$ $P(R_5 \bar{C}_4,C_7,C_8)=0.60; P(R_5 \bar{C}_4,C_7,\bar{C}_8)=0.50$ $P(R_5 \bar{C}_4,\bar{C}_7,C_8)=0.50; P(R_5 \bar{C}_4,\bar{C}_7,\bar{C}_8)=0.35$
是否违背准则 R_6	R_6	$P(R_6 C_4,C_7,C_8)=0.90; P(R_6 C_4,C_7,\bar{C}_8)=0.75$ $P(R_6 C_4,\bar{C}_7,C_8)=0.80; P(R_6 C_4,\bar{C}_7,\bar{C}_8)=0.60$ $P(R_6 \bar{C}_4,C_7,C_8)=0.70; P(R_6 \bar{C}_4,C_7,\bar{C}_8)=0.55$ $P(R_6 \bar{C}_4,\bar{C}_7,C_8)=0.50; P(R_6 \bar{C}_4,\bar{C}_7,\bar{C}_8)=0.10$
是否违背准则 R_7	R_7	$P(R_7 C_5)=0.90; P(R_7 \bar{C}_5)=0.10$
是否违背准则 R_8	R_8	$P(R_8 C_2,C_5,C_6)=0.95; P(R_8 C_2,C_5,\bar{C}_6)=0.65$ $P(R_8 C_2,\bar{C}_5,C_6)=0.85; P(R_8 C_2,\bar{C}_5,\bar{C}_6)=0.55$ $P(R_8 \bar{C}_2,C_5,C_6)=0.75; P(R_8 \bar{C}_2,\bar{C}_5,C_6)=0.60$ $P(R_8 \bar{C}_2,C_5,\bar{C}_6)=0.40; P(R_8 \bar{C}_2,\bar{C}_5,\bar{C}_6)=0.10$

表 4 控制图方差异常诊断网络概率表

条件	$P(S=U)$	$P(S=C)$	$P(S=L)$
$\bar{C}_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.20	0.60	0.20
$C_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.60	0.30	0.10
$\bar{C}_1,C_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.60	0.30	0.10
$\bar{C}_1,\bar{C}_2,C_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.70	0.25	0.05
$\bar{C}_1,\bar{C}_2,\bar{C}_3,C_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.55	0.30	0.15
$\bar{C}_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,C_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.10	0.40	0.50
$\bar{C}_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,C_6,\bar{C}_7,\bar{C}_8$	0.80	0.15	0.05
$\bar{C}_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,C_7,\bar{C}_8$	0.50	0.40	0.10
$\bar{C}_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,\bar{C}_5,\bar{C}_6,\bar{C}_7,C_8$	0.65	0.25	0.10
$C_1,\bar{C}_2,\bar{C}_3,\bar{C}_4,C_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.30	0.30	0.40
$\bar{C}_1,C_2,\bar{C}_3,\bar{C}_4,C_5,\bar{C}_6,\bar{C}_7,\bar{C}_8$	0.20	0.30	0.50

续表

条件	$P(S=U)$	$P(S=C)$	$P(S=L)$
$\overline{C_1}, \overline{C_2}, C_3, \overline{C_4}, C_5, \overline{C_6}, \overline{C_7}, \overline{C_8}$	0.40	0.20	0.40
$\overline{C_1}, \overline{C_2}, \overline{C_3}, C_4, C_5, \overline{C_6}, \overline{C_7}, \overline{C_8}$	0.20	0.30	0.50
$\overline{C_1}, \overline{C_2}, \overline{C_3}, \overline{C_4}, C_5, C_6, \overline{C_7}, \overline{C_8}$	0.60	0.20	0.20
$\overline{C_1}, \overline{C_2}, \overline{C_3}, \overline{C_4}, C_5, \overline{C_6}, C_7, \overline{C_8}$	0.40	0.20	0.20
$\overline{C_1}, \overline{C_2}, \overline{C_3}, \overline{C_4}, C_5, \overline{C_6}, \overline{C_7}, C_8$	0.40	0.20	0.40
其他情况	0.90	0.08	0.02

注:表中条件加上划线表示不发生,反之发生。

表 5 控制图异常诊断网的根节点概率表
(原因节点先验概率)

变量名称	符号	先验概率
加工误操作	C_1	$P(C_1 P)=0.27$
操作不熟练	C_2	$P(C_2 P)=0.23$
设备故障	C_3	$P(C_3 P)=0.15$
刀具磨损	C_4	$P(C_4 P)=0.18$
数据作弊	C_5	$P(C_5 P)=0.20$
量仪精度低	C_6	$P(C_6 P)=0.12$
夹具安装错误	C_7	$P(C_7 P)=0.21$
设备振动厉害	C_8	$P(C_8 P)=0.15$

3 应用实例

以汽轮机转子生产过程中叶轮直径监控为例,设备产生故障,控制图出现以下异常:①有一点超出了上控制线,即 R_1 发生;②控制图数据点连续 6 点递增,即 R_3 发生;③方差明显偏大,即 $S=U$ 发生。下面,诊断控制图异常的原因。

根据建立的基于贝叶斯网络的制造过程异常诊断模型,主要考虑原因 $C_1、C_2、C_3$,并假设它们发生的概率均等,均为 0.200 0,见表 6 初始状态一栏。

(1)计算各征兆的边缘概率,依据本文所建立的模型,应用全概率公式计算征兆的边缘概率

$$P(R)=\sum_cP(C)P(R|C)$$

式中: C 为与异常征兆 R 相关联的原因节点; $P(R_1)=0.253\ 6,P(R_3)=0.293\ 6,P(S=U)=0.624\ 0$ 。当获得证据 1 时,将 R_1 取值“T”的概率置 1。

(2)计算各原因发生的概率,即计算 $P(C|R)$ 。诊断过程中所获得的事实为 R ,在本文模型中,已知的是各节点的概率表,则任一节点 c 的边缘概率密度如下

$$P(C|R)=\frac{P(C,R)}{P(R)}=\frac{P(R)P(R|C)}{P(R)}$$

$P(R|C)$ 可以看作是将节点概率表看作局部联合概率,计算 C 的边缘分布公式如下

$$P(R|C)=\sum_{P_a/C}P(R|P_a)$$

式中: P_a 为与征兆 R 相关联的原因节点组合。经推理,得到获得证据 1 后 $C_1、C_2、C_3$ 的后验概率变为表格“获得证据 1”对应的数据,可以看出它们都发生了变化,且 C_1 的概率略高。

(3)将获得的后验概率作为证据 2 推理的先验概率,此时可以计算出 $R_1、R_3、S=U$ 的边缘概率变为: $P(R_1)=0.453\ 0,P(R_3)=0.392\ 4,P(S=U)=0.640\ 3$ 。将 R_3 取值“T”的概率置 1。

(4)按照(1)、(2)对整个贝叶网络进行推理,得到获得证据 2 后 $C_1、C_2、C_3$ 的后验概率变为表格“获得证据 2”对应的数据,可以看出它们都发生了变化, C_3 的概率明显较高。

表 6 异常原因概率表

状态	$P(C)$		
	C_1	C_2	C_3
初始状态	0.200 0	0.200 0	0.200 0
获得证据 1	0.400 6	0.324 9	0.394 3
获得证据 2	0.453 0	0.392 4	0.640 3
获得证据 3	0.470 1	0.415 5	0.671 2

(5)将获得的后验概率作为证据 3 推理的先验概率,此时可以计算出 $R_1、R_3、S=U$ 的边缘概率变为: $P(R_1)=0.470\ 1,P(R_3)=0.415\ 5,P(S=U)=0.671\ 2$ 。将 S 取值“U”的概率置 1。

(6)按照步骤(1)(2)对整个贝叶网络进行推理,得到获得证据 3 后 $C_1、C_2、C_3$ 的后验概率变为表格“获得证据 3”对应的数据,可以看出它们都发生了变化, C_3 的概率仍然高于 $C_1、C_2$ 。

通过这 3 个证据可以看出, C_3 发生问题的可能性最大,即设备故障发生的可能性最大,与实际异常原因一致,故采用贝叶斯网络统计异常诊断有效。

4 结 论

贝叶斯网络将先验认识和历史经验以节点关系和概率表形式体现出来,本文将贝叶斯网络推理引入到制造过程异常的诊断中,利用控制图的异常特征推理控制图异常的原因,给出了使用贝叶斯网络进行统计异常诊断建模的过程和异常推理过程,验证了使用贝叶斯网络推理方法进行统计异常诊断的可行性和有效性。在后期工作过程中,可以进一步扩展该模型,考虑更多相关质量特性控制图,进一步提高异常诊断的准确率。

参考文献:

- [1] 苏秦. 质量管理与可靠性 [M]. 北京: 机械工业出版社, 2006: 1-4.
- [2] 张公绪, 孙静. 两种质量多元诊断理论应用实例 [J]. 中国质量, 2002(8): 30-33.
ZHANG Gongxu, SUN Jing. A case study of the multivariate diagnostic theory with two kinds of quality [J]. China Quality, 2002(8): 30-33.
- [3] 卓德保, 徐济超. 质量诊断技术及其应用综述 [J]. 系统工程学报, 2008, 23(3): 338-346.
ZHUO Debao, XU Jichao. Survey of techniques and applications on quality diagnosis [J]. Journal of Systems Engineering, 2008, 23(3): 338-346.
- [4] 程志强. 基于智能方法的产品制造过程质量诊断 [D]. 南京: 南京理工大学, 2011: 4-6.
- [5] APLEY D W, LEE H Y. Simultaneous identification of premodeled and unmodeled variation patterns [J]. Journal of Quality Technology, 2010, 42(1): 36-51.
- [6] 赵永满. 多元过程监控与异常诊断研究 [D]. 天津: 天津大学, 2012: 6-8.
- [7] 程红军. 基于神经网络的多元质量控制与诊断技术研究 [D]. 天津: 天津大学, 2008: 17-45.
- [8] ATASHGAR K. Monitoring multivariate environments using artificial neural network approach: an overview [J]. Scientia Kanica, 2015, 22(6): 2527-2547.
- [9] SALEHI M, KAZEMZADEH R B, SALMASNIA A. On line detection of mean and variance shift using neural networks and support vector machine in multivariate processes [J]. Applied Soft Computing, 2012, 12(9): 2973-2984.
- [10] 项前, 徐兰, 刘彬, 等. 基于粗糙集与支持向量机的加工过程异常检测 [J]. 计算机集成制造系统, 2015, 21(9): 2467-2474.
XIANG Qian, XU Lan, LIU Bin, et al. Processing anomaly detection based on rough set and support vector machine [J]. Computer Integrated Manufacturing Systems, 2015, 21(9): 2467-2474.
- [11] 肖承杭. 基于决策树的多元过程控制与异常识别方法研究 [D]. 天津: 天津大学, 2012: 29-41.
- [12] 黄影平. 贝叶斯网络发展及其应用综述 [J]. 北京理工大学学报, 2013, 33(12): 1211-1219.
HUANG Yingping. Survey on Bayesian network development and application [J]. Transactions of Beijing Institute of Technology, 2013, 33(12): 1211-1219.
- [13] CAI Baoping, HUA Lei, XIE Min. Bayesian networks in fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2017, 13(5): 2227-2240.
- [14] LIN S, CHEN X, WANG Q. Fault diagnosis model based on Bayesian network considering information uncertainty and its application in traction power supply system [J]. IEEJ Transactions on Electrical and Electronic Engineering, 2018, 13(5): 671-680.
- [15] 罗孝辉, 童晓阳. 计及可信度的变结构贝叶斯网络电网故障诊断 [J]. 电网技术, 2015, 39(9): 2658-2664.
LUO Xiaohui, TONG Xiaoyang. Structure-variable Bayesian network for power system fault diagnosis considering credibility [J]. Power System Technology, 2015, 39(9): 2658-2664.
- [16] BI Z, LI C M, LI X J, et al. Research on fault diagnosis for pumping station based on T-S fuzzy fault tree and Bayesian network [J]. Journal of Electrical & Computer Engineering, 2017, 2017(11): 1-7.
- [17] 梁潇, 王海峰, 郭进, 等. 基于贝叶斯网络的列控车载设备故障诊断方法 [J]. 铁道学报, 2017, 39(8): 93-100.
LIANG Xiao, WANG Haifeng, GUO Jin, et al. Bayesian network based fault diagnosis method for on-board equipment of train control system [J]. Journal of the China Railway Society, 2017, 39(8): 93-100.
- [18] 曹杰. 贝叶斯网络结构学习与应用研究 [D]. 合肥: 中国科学技术大学, 2017: 11-14.

(编辑 杜秀杰)