

基于 Petri 网的测试-故障诊断一体化模型研究*

翟禹尧, 史贤俊, 韩露, 秦玉峰

(海军航空大学岸防兵学院 烟台, 264001)

摘要 现有测试性模型对复杂装备进行分层建模时,不仅需要每层装备的故障模式、影响和危害性分析(failure mode, effects and criticality analysis,简称FMECA),还需要确定各故障模式之间的联系,增加了实际工作量和建模难度,与实际故障诊断脱节。为解决上述问题,提出一种基于Petri网的建模方法,将测试性模型与故障诊断模型相结合。首先,采用广义随机Petri网建立装备系统级的测试性模型,采用模糊Petri网(fuzzy Petri net,简称FPN)建立子系统的故障诊断模型,完成系统到子系统的传递;其次,根据FMECA信息对故障统计数据进行处理,通过神经网络对参数进行调整学习和优化;然后,采用正向推理实现故障的准确预测,逆向推理结合最小割集完成故障定位;最后,以涡扇发动机风扇部件模型为例进行建模分析,并通过故障树和统计数据验证了模型的正确性和有效性。

关键词 测试性;故障树;故障模式;Petri网;故障诊断模型;神经网络

中图分类号 TH165+.3;TP206+.3

引言

多信号模型是最广泛应用的测试性模型,但其缺点是系统之间的内在联系^[1]不能完整地表达出来,具体表现为:仅用0和1描述系统故障与测试之间的关系,忽略测试不可靠、延时性等有用信息,该建模方法存在局限性。现有模型对复杂系统进行建模会导致分析结果不全面^[2],具体表现为:系统故障原因具有多样性、模糊性及偶然性,而故障与故障之间存在复杂的逻辑关系,现有模型并不能对上述分析进行有效描述,也不能动态描述故障的产生及诊断过程,缺乏灵活性,最终导致模型不够完备,所建模型与实际模型误差较大。

Petri网是目前用来故障诊断的一种方法,既能表现系统的状态,又能描述系统的行为^[3]。目前用来故障诊断^[4]的Petri网可分为两类,故障Petri网^[5]和随机Petri网^[6]。王瑶^[7]对四性工作开展了深入研究,采用Petri网建立四性一体化模型,虽建立系统测试性模型,但主要针对四性进行分析,测试性模型研究不够深入。文献[8]提出采用广义随机Petri网对系统进行测试性建模,不仅将现有模型与Petri

网模型的优缺点进行了对比,还对复杂系统进行了分层建模。FPN属于故障Petri网的一种,不仅能够描述系统的状态,还能够采用模糊推理描述故障征兆和故障之间的对应关系。文献[9]采用加权模糊Petri网(weighted fuzzy Petri net,简称WFPN)对电网进行了故障诊断,取得了不错的效果。

在文献[8]工作的基础上,将FPN与系统级测试性模型相结合,完成由系统到子系统的传递。只需知道装备的FMECA信息,就可以建立模型进行分析,该模型不仅考虑了系统结构特性,且能够处理复杂的故障传播过程,具有严格的数学推理算法,可以将故障的传播过程定量转化为数学方程。根据系统测试性模型得到测试性指标,指导装备的机内测试(build in test,简称BIT)设计,根据子系统的FPN模型实现对故障的精确定位以及故障的预测。

1 FPN描述

1.1 FPN的定义

定义1 一个FPN由一个十一元组构成^[9-10],记为 $FPN=(P, T; D, I, O, M, W, \alpha, F, \lambda, U)$,其中:

* 国家自然科学基金青年科学基金资助项目(61903374)
收稿日期:2020-01-04;修回日期:2020-07-06

$P = \{p_1, p_2, \dots, p_n\}$ 为有限库所集合; $T = \{T_1, T_2, \dots, T_m\}$ 为有限变迁集合; $D = \{D_1, D_2, \dots, D_n\}$ 为命题的有限集合, $|P| = |D|$, $P \cap T \cap D = \emptyset$; $I: T \rightarrow P^\infty$, 为输入矩阵, 反映变迁到库所映射的矩阵; $O: T \rightarrow P^\infty$, 为输出矩阵, 反映库所到变迁映射的矩阵; $M = (m_1, m_2, \dots, m_n)^T$ 表示库所标识分布向量; $W = (\omega_{ij})$ 为库所权值 $n \times m$ 矩阵; $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$ 为库所置信度 n 维向量; $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_m)^T$ 为变迁点火的阈值向量; $U = \text{diag}(\mu_1, \mu_2, \dots, \mu_n)$ 为变迁规则可信度矩阵; F 为一有向弧的集合, $F \subseteq (P \times T) \cup (T \times P)$, \times 为笛卡尔积。

定义 2 在模糊产生式规则中, 如果其前提条件或结论中存在“and”, “or”, 称此规则为合成式规则。本研究涉及两种规则类型如下

if d_1 and d_2 and \dots and d_n then $d(CF = \mu_i)$

if d_1 or d_2 or \dots or d_n then $d(CF = \mu_i)$

其中: d 为结果命题。

1.2 FPN 的参数学习

权值等参数源于专家的经验与装备的历史数据, 存在着不准确和无法学习的问题, 很难转化为具体的模糊值。采用 BP 神经网络进行参数学习, 从而优化故障诊断模型。

神经网络对 FPN 参数训练算法, 以权值为例进行论述。初始化误差阈值、迭代次数和学习率, 步骤如下。

1) 将学习样本进行归一化处理, 以建立规范的样本。

2) 建立如图 1 所示的神经网络模型, 包括输入层节点 I 、隐藏层节点 M 和输出层节点 O 。其中: I 与样本数相同; O 根据故障数来确定; M 可以根据式(1)来确定

$$M = \sqrt{I + O} + C \quad (1)$$

其中: C 为 1~10 之间的一个随机常数。

3) 对步骤 2 的模型进行训练, 得到权值等参数的初始值。

4) 误差函数如式(2)所示

$$E = 1/2 \sum_{i=1}^N \sum_{j=1}^L [\alpha(p_j) - \hat{\alpha}(p_j)]^2 \quad (2)$$

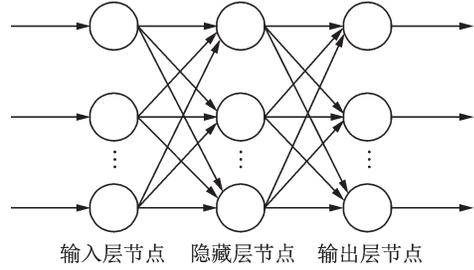


图1 3层BP神经网络模型

Fig.1 Three-layer BP neural network model

根据 window-Hoff 规则来修正权值, 在第 j 次迭代中, 调整权值的计算公式为

$$\omega_{ij}^{(r)}(t+1) = \omega_{ij}^{(r)}(t) - \eta dE/d\omega_{ij}^{(r)} \quad (3)$$

5) $j = j + 1$, 当 j 达到最大迭代次数, 算法结束, 权值可以通过式(3)获得, FPN 经过神经网络学习训练变成神经模糊 Petri 网(neural fuzzy Petri net, 简称 NFPN)。

2 NFPN 诊断推理算法

在进行故障推理之前, 需要定义如下数学算子^[11]。

1) 比较算子 \square : $C = A \square B$ 。 A, B 和 C 均为 $m \times n$ 矩阵, 当 $a_{ij} > b_{ij}$ 时 $c_{ij} = 1$; 当 $a_{ij} < b_{ij}$ 时 $c_{ij} = 0$ 。其中: $i = 1, 2, \dots, m; j = 1, 2, \dots, n$ 。

2) 取小算子 \odot : $C = A \odot B$ 。 A, B 和 C 均为 $m \times n$ 矩阵, $c_{ij} = \min(a_{ij}, b_{ij})$ 。

3) 取大算子 \oplus : $C = A \oplus B$ 。 A, B 和 C 均为 $m \times n$ 矩阵, $c_{ij} = \max(a_{ij}, b_{ij})$ 。

4) 直乘算子 $*$: $C = A * b$ 。 A 为 $m \times n$ 矩阵, b 为 n 维向量, $c_{ij} = a_{ij} \cdot b_i$ 。

5) 乘法算子 \otimes : $C = A \otimes B$ 。 A, B 和 C 分别为 $m \times q, q \times n, m \times n$ 矩阵, $c_{ij} = \max(a_{ik} b_{kj})$

2.1 正向推理算法

首先, 根据 FMECA 获取故障征兆信息, 确定库所置信度; 其次, 根据点火判别函数进行判断变迁的发生, 根据关联矩阵(由输入矩阵和输出矩阵构成)进行故障传播的推理, 以实现故障的预测与防护^[12]。

2.1.1 库所置信度推理

推理公式为

$$\alpha^{k+1} = \alpha^k \oplus [(O \cdot U) \otimes (W \cdot \alpha^k)] \quad (4)$$

表 1 风扇部件 FMECA 信息

Tab.1 FMECA information of Fan component

故障模式	故障征兆	故障严酷度
风扇效率低	1) 叶尖径向间隙过大	II
	2) 进气道出口流场畸变较大	
	3) 叶片型面加工误差	
	4) 叶片损伤	
	5) 共同工作线位不合适	
叶片裂纹、变形或断裂	1) 外物损伤	II
	2) 叶片疲劳损伤	
	3) 叶片产颤振	
喘振	1) 进气道出口气流畸变度偏高	II
	2) 叶片损伤,叶片流道内流场恶化	
	3) 控制程序交叠	
风扇轴转扭 花键损伤 (过度磨损、 冲击损伤、 断裂)	1) 装备质量不好 2) 承受过大载荷 3) 疲劳损伤	II
风扇轴裂纹 或折断	1) 疲劳损伤 2) 承受过大载荷	II

表 2 测试性模型的库所和变迁的具体含义

Tab.2 The specific meaning of the library and changes

库所	编码	含义
p_{a1}	001-OG.1	风扇部件故障
p_{a2}	002-OG.1	压气机部件故障
p_{a3}	003-OG.1	燃烧室部件故障
p_{a4}	004-OG.1	高压涡轮部件故障
p_{a5}	005-OG.1	低压涡轮部件故障
p_{a6}	006-YW.1	内涵尾喷管
p_{a7}	007-YW.1	外涵尾喷管

点,为故障诊断奠定基础。笔者以风扇部件为例,进行故障分析。

4.1 初值的确定

根据 2.1 节中所述的方法,借助于专家经验对模型中的各参数的初值进行确定。

初始库所置信度 $\alpha_0^T = (0.92, 0.69, 0.89, 0.9, 0.87, 0.75, 0.72, 0.86, 0.93, 0.77, 0.67, 0.63, 0, 0, 0, 0, 0)$

变迁置信度 $U = \text{diag}(0.87, 0.82, 0.78, 0.72, 0.90, 0.88, 0.87, 0.91, 0.66, 0.88, 0.90, 0.87)$ 。

阈值 $\lambda^T = (0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5, 0.5,$

表 3 FPN 模型的库所和变迁的具体含义

Tab.3 The specific meaning of the library and changes

库所	编码	含义
p_{13}	001-OG.1	风扇效率低
p_{14}	001-OG.2	叶片裂纹、变形或断裂
p_{15}	001-OG.3	喘振
p_{16}	001-OG.4	风扇轴转扭花键损伤
p_{17}	001-OG.5	风扇轴裂纹或折断
p_1	001-OG.11	叶尖径向间隙过大
p_2	001-OG.12	进气道出口流场畸变较大
p_3	001-OG.13	叶片型面加工误差
p_4	001-OG.14	叶片损伤
p_5	001-OG.15	共同工作线位不合适
p_6	001-OG.21	外物损伤
p_7	001-OG.23	叶片产颤振
p_8	001-OG.31	进气道出口气流畸变度偏高
p_9	001-OG.33	控制程序交叠
p_{10}	001-OG.41	装备质量不好
p_{11}	001-OG.42	承受过大荷载
p_{12}	001-OG.43	疲劳损伤

表 4 相关性矩阵

Tab.4 Correlation matrix

故障测试	T_1	T_2	T_3	T_4
001-OG.1	1	1	1	1
002-OG.1	0	1	1	1
003-OG.1	0	1	1	1
004-OG.1	0	0	1	1
005-OG.1	0	0	0	1
006-YW.1	0	0	0	1
007-YW.1	1	0	0	0

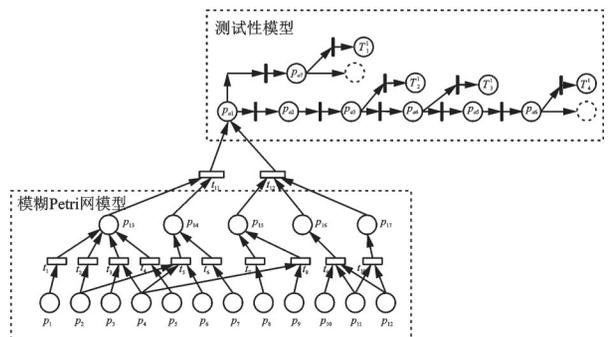


图 3 测试性-故障诊断模型

Fig.3 Testability-fault diagnosis integrated model

0.5, 0.5, 0.5, 0.5)。

本研究以叶片裂纹、变形或断裂 p_{15} 、风扇轴裂

障的全部库所,如图 6 所示。标识向量 $M_2^-(0, 0, 0, 0, 0, 0, 1, 0, 1, 1, 1, 0, 0, 1, 1, 1, 1)^T$ 。

根据图 5 中的事件关系,可求得引发风扇部件故障的最小割集: $G_3 = \{p_8\}$, $G_4 = \{p_{10}, p_{11}, p_{12}\}$, $G_5 = \{p_{11}, p_{12}\}$; $f(G_3) = 0.86$, $f(G_4) = 0.69$, $f(G_5) = 0.65$ 。通过最小割集发生率,可以得到故障的诊断先后顺序为 G_3, G_4, G_5 。当一个故障由多个故障征兆的库所引发时,例如 G_5 ,根据 p_{11} 和 p_{12} 置信度高低进行诊断。反向推理算法与传统故障检测方法相比,在提高检测效率的同时,还避免了检测过程中的盲目性和复杂性。

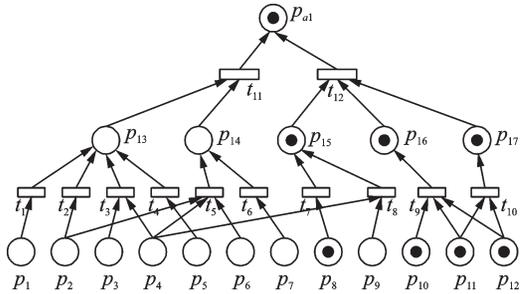


图 5 反向推理结束的托肯分布
Fig.5 Adverse inference end token distribution

5 推理验证

5.1 正向推理验证

故障诊断领域常用的方法之一为故障树分析 (fault tree analysis, 简称 FTA), 笔者通过建立系统的故障树对正向推理进行验证。图 6 是以风扇部件为例的故障树模型, 事件含义如表 2、表 3 所示, 其中 p_3 和 p_4 由或门连接之后与 p_1, p_2, p_5 通过与门相连接。为了推理方便, 将 p_3 和 p_4 由或门连接之后的隐藏事件用 X_1 表示, X_1 无具体含义, 只是方便叙述下面求解演算, 类似的还有 X_2, X_3, X_4 和 X_5 。

将 5.1 节中的置信度、权值和阈值等模糊信息引入故障树。以事件 p_2, p_4, p_6 和 p_9 为例, $p_2 = 0.69$, $p_4 = 0.9$, $p_6 = 0.75$, $p_9 = 0.93$ 。 $\omega_{2,2} = 1$, $\omega_{2,5} = 0.33$, $\omega_{4,5} = 0.46$, $\omega_{6,5} = 0.21$, $\omega_{4,8} = 0.64$, $\omega_{9,8} = 0.36$ 。根据 1.2 节中的模糊推理算法, $p_2 \omega_{2,2} = 0.69 > 0.5$, $p_2 \omega_{2,5} + p_4 \omega_{4,5} + p_6 \omega_{6,5} = 0.80 > 0.5$, $p_4 \omega_{4,8} + p_9 \omega_{9,8} = 0.91 > 0.5$ 。求解之后, $p_{13} = 0.69$, $p_{14} = 0.91$, $p_{15} = 0.91$, 相应的权值 $\omega_{13,11} = 0.58$, $\omega_{14,11} = 0.42$, $X_4 = p_{13} \omega_{13,11} + p_{14} \omega_{14,11} = 0.78 > 0.5$ 。 p_{15}, p_{16}, p_{17} 通过或

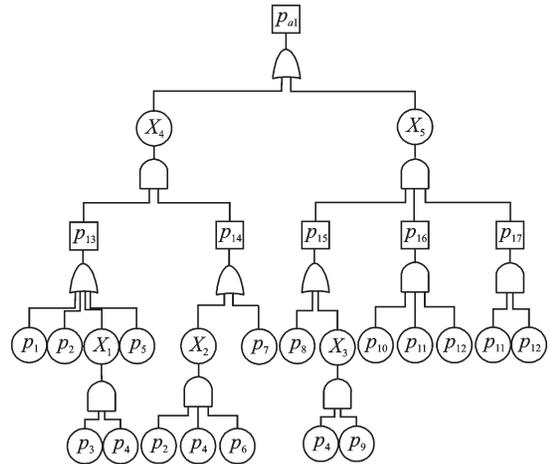


图 6 故障树模型

Fig.6 The fault tree model

门连接, 依据模糊产生规则, 不满足继续传递条件。因此, 由 X_4 导致 p_{a1} 风扇部件故障, 与正向推理结论一致, 验证了正向推理的正确性。

5.2 反向推理验证

表 5 为某型号涡扇发动机 2010—2019 年期间记录的风扇部件维修记录数据, 进行统计处理后验证反向推理的正确性。

表 5 风扇部件维修记录数据

Tab.5 Fan component maintenance record data

易损件及标准件		故障情况及检修记录			
序号	名称	严酷度等级	维修日期	故障记录	检查内容
1	风扇轴	II	2010-10-11	例行检修	p_{16}, p_{17}
2	风扇轮	II	2013-10-20	例行检修	p_2, p_8
3	叶片	II	2016-09-30	风扇喘振	p_{14}
4	控制软件	II	2019-10-15	控制程序交叠	p_9

表 6 记录了风扇部件故障现象及故障原因等数据, 该部件在这期间总共发生 329 次故障。因为时间长、尚未妥善保存等因素造成部分数据损毁或丢失, 为了数据的真实性和准确性, 用“其他”原因表征这部分数据。根据表 6 中的故障统计次数和库所置信度求取相关性系数, 由相关性系数的高低判断反向推理的准确性。故障统计次数平均值 $\bar{X} = 54.833$, 置信度的平均值 $\bar{Y} = 0.568$, 将二者代入式 (10), 得到 $r = 0.899$ 。

表 6 故障记录相关数据
Tab.6 Fault recording data

故障现象	故障原因	故障记录统计次数	故障现象库所置信度
p_{13}	p_1, p_2, p_3, p_4, p_5	96	0.80
p_{14}	p_2, p_4, p_6, p_7	68	0.73
p_{15}	p_4, p_8, p_9	87	0.83
p_{16}	p_{10}, p_{11}, p_{12}	30	0.46
p_{17}	p_{11}, p_{12}	41	0.59
p_{13}	其他	7	0

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (10)$$

根据相关性定义可确定,推理结果与实际故障状态具有较强的相关性。

进一步与文献[15-16]进行对比来验证本研究方法的准确性。选取现场 2 个案例,应用 3 种方法进行

分析。表 7 为 3 种方法对比结果,考虑实际工作情况, p_9 为控制程序必须检测。根据表 7 能得到本研究与文献[15]具有相同诊断结果,稍优于文献[16]。文献[15]采用专家诊断系统和基于 BP 神经网络的故障诊断模型,该方法诊断率高、针对性强,但是需要大量实际数据作为支撑,不同装备的数据获取难度不一样,难以推广。文献[16]是基于云神经网络的故障诊断模型,引入改进的自适应遗传算法,保证了故障诊断的精度和效率,但是该文主要对算法进行改进,文中数据靠神经网络进行模拟训练,数据的可信度难以得到保证,装备出厂时会有相应的 FMECA 信息。本研究则是根据 FMECA 信息和系统结构框图建立装备的测试-故障诊断一体化模型,根据测试性模型对系统进行测试性设计,根据 FPN 对子系统进行故障诊断,该模型不仅能够处理复杂的故障传播过程,还可以根据推理算法将该过程定量转化为数学模型,对故障进行精确定位以及故障预测。

表 7 与其他方法诊断结果的比较

Tab.7 Diagnostic results compared with different models

案例	故障现象	现场诊断结果	现场诊断故障模式	诊断方法	诊断结果正确性	结果漏检	结果误判
1	风扇部件故障	p_{13}	风扇转子封严篦齿与整流器的径向间隙不符合要求	文献[15]	$p_1 p_2 p_8$	无	无
				文献[16]	$p_2 p_8$	p_1	无
				本研究	$p_1 p_2 p_8$	无	无
2	风扇部件故障	p_{15}	喘振	文献[15]	$p_4 p_8$	无	无
				文献[16]	$p_4 p_8$	无	无
				本研究	$p_4 p_8 p_9$	无	p_9

6 结 论

1) 提出基于 Petri 网的测试-故障诊断一体化模型,该模型同时兼备测试性设计和故障诊断等功能。

2) 对 FPN 的定义和元素的组成进行了详细的论述,采用神经网络对权值等参数进行优化调整,弥补了参数依赖专家经验以及不准确的问题。FPN 经过神经网络学习训练变成 NFPN。

3) 以风扇部件为例,建立其系统级测试性模型和子系统的 NFPN 模型。根据相关性矩阵得到测试性指标,指导 BIT 设计。对子系统的 NFPN 模型进行正、反推理,将故障传播过程定量转化为数学方程,对故障进行精确定位,避免了故障检测的盲目性和复杂性。

4) 通过故障树和实际故障数据对推理算法进行验证,证明了本研究模型和算法的有效性。

参 考 文 献

[1] 田仲,石君友.系统测试性设计分析与验证[M].北京:北京航空航天大学出版社,2003:17-19.

[2] 尹园威,尚朝轩,马彦恒,等.层次测试性模型的评估方法[J].北京航空航天大学学报,2015,41(1):90-95.

YIN Yuanwei, SHANG Chaoxuan, MA Yanheng, et al. Method of testability evaluation using hierarchical testability model [J]. Journal of Beijing University of Aeronautics and Astronautics, 2015, 41(1):90-95. (in Chinese)

- [3] 林闯. 随机Petri网和系统性能评价[M]. 北京:清华大学出版社, 2005:19-35.
- [4] MAHULEA C, SEATZU C, CABASINO M P, et al. Fault diagnosis of discrete-event systems using continuous Petri nets [J]. *Systems, Man and Cybernetics, Part A: Systems and Humans*, IEEE Transactions on, 2012, 42(4): 970-984.
- [5] MANSOUR M M, WAHAB M A A, SOLIMAN W M. Petri nets for fault diagnosis of large power generation station[J]. *Ain Shams Engineering Journal*, 2013, 4(4): 831-842.
- [6] CODETTA-RAITERI D. The conversion of dynamic fault trees to stochastic Petri nets, as a case of graph transformation [J]. *Electronic Notes in Theoretical Computer Science*, 2005, 127(2): 45-60.
- [7] 王瑶. 基于Petri网的四性一体化建模及仿真方法研究[D]. 西安:西北工业大学, 2016.
- [8] 翟禹尧, 史贤俊, 秦玉峰, 等. 基于层次广义随机Petri网的测试性建模新方法[J]. *兵工学报*, 2020, 41(1): 161-170.
ZHAI Yuyao, SHI Xianjun, QIN Yufeng, et al. A new testability model method based on hierarchical generalized stochastic Petri nets [J]. *Acta Armamentarii*, 2020, 40(1): 161-170. (in Chinese)
- [9] 陈强, 程学珍, 刘建航, 等. 基于分层变迁的WFPN电网故障分析[J]. *电工技术学报*, 2016, 31(15): 125-135.
CHEN Qiang, CHENG Xuezheng, LIU Jianhang, et al. The analysis method of power grid fault based on hierarchical transition weighted fuzzy Petri net [J]. *Transactions of China Electrotechnical Society*, 2016, 31(15): 125-135. (in Chinese)
- [10] WANG L, CHEN Q, GAO Z J, et al. Knowledge representation and general Petri net models for power grid fault diagnosis [J]. *IET Generation, Transmission & Distribution*, 2015, 9(9): 866-873.
- [11] LUO X, KEZUNOVIC M. Implementing fuzzy reasoning Petri-nets for fault section estimation [J]. *IEEE Transactions on Power Delivery*, 2008, 23(2): 676-685.
- [12] EDWARDS C J, DAVIDSON E M, MCARTHUR S D J, et al. Flexible model-based alarm processing for protection performance assessment and incident identification [J]. *IEEE Transactions on Power Systems*, 2018, 28(3): 2584-2591.
- [13] 谢倩, 乐晓波, 周恺卿, 等. 模糊Petri网库所集中token初始值的确定方法[J]. *计算机工程与应用*, 2012, 48(12): 49-52, 62.
XIE Qian, YUE Xiaobo, ZHOU Kaiqing, et al. Determination of token in initial place of fuzzy Petri nets [J]. *Computer Engineering*, 2012, 48(12): 49-52, 62. (in Chinese)
- [14] HE Z Y, YANG J W, ZENG Q F, et al. Fault section estimation for power systems based on adaptive fuzzy Petri nets [J]. *International Journal of Computational Intelligence Systems*, 2014, 7(4): 605-614.
- [15] 张莹松, 吴灿, 唐海龙, 等. 基于故障检测的某涡扇发动机维修决策方法[J]. *航空动力学报*, 2017, 32(1): 82-88.
ZHANG Yingsong, WU Can, TANG Hailong, et al. Maintenance decision method of a turbofan engine based on fault detection [J]. *Journal of Aerospace Power*, 2017, 32(1): 82-88. (in Chinese)
- [16] 王修岩, 谷新铭, 高铭阳, 等. 基于一种改进的云神经网络涡扇发动机故障诊断[J]. *计算机工程与应用*, 2014, 22(4): 988-990.
WANG Xiuyan, GU Xinming, GAO Mingyang, et al. Fault diagnosis of aeroengine's steady regular inspection based on cloud model and neural network [J]. *Computer Measurement & Control*, 2014, 22(4): 988-990. (in Chinese)



第一作者简介:翟禹尧,男,1991年2月生,博士生。主要研究方向为测试性与故障诊断。曾发表《基于广义随机Petri网的导弹系统测试性建模与指标评估方法研究》(《兵工学报》2019年第40卷第10期)等论文。

E-mail: 412997283@qq.com