

基于置信规则库的海基系统性能退化机理分析与预测

韩润繁¹, 陈桂明¹, 常雷雷^{1†}, 凌晓东²

(1. 火箭军工程大学 作战保障学院, 西安 710025;

2. 中国卫星海上测控部飞行器海上测量与测控联合实验室, 江苏 江阴 214431)

摘要: 海基系统性能退化机理分析和预测对于提高海基系统的生存能力具有重要意义,但需要考虑不确定条件下的多种类型信息,传统方法在处理海基系统的不确定性时效果欠佳,而置信规则库(BRB)作为证据推理方法中的知识库又无法同时处理参数精度优化和组合爆炸问题.对此,采用BRB参数与结构联合优化方法,建立双层优化的海基系统置信规则库最优决策结构,以AIC(Akaike information criterion)为外层模型优化目标,MSE(Mean square error)为内层模型优化目标,实现同时优化的目的.对比模型输出和实际输出,并采用支持向量机(SVM)进行实验,结果表明,采用具有最优决策结构的海基系统置信规则库建模不仅可以降低模型中规则的数量,也可提高建模精度,验证了所提出方法的有效性.

关键词: 海基系统; 退化分析; 预测; 置信规则库

中图分类号: TP273

文献标志码: A

Degradation mechanism analysis and prediction of maritime based system performance using belief rule base

HAN Run-fan¹, CHEN Gui-ming¹, CHANG Lei-lei^{1†}, LING Xiao-dong²

(1. College of Combatant Logistic, Rocket Force University of Engineering, Xi'an 710025, China; 2. China Satellite Maritime Tracking and Control Laboratory, Jiangyin 214431, China)

Abstract: The degradation mechanism analysis and prediction of the maritime-based system performance is vital for improving the survivability of the maritime-based systems. However, traditional methods can't deal with uncertainty well since many types of information under uncertainty need to be taken into consideration. As the knowledge base of the evidential reasoning approach, the belief rule base (BRB) can not optimize the modeling complexity and modeling accuracy at the same time. In this study, the structure and parameters of the BRB are jointly optimized to construct a bi-level maritime-based system BRB model. In the bi-level model, the Akaike information criterion (AIC) and mean square error (MSE) are used as the upper-level and lower-level optimization objectives, respectively. By comparing the model outputs with actual outputs, the results of the experiment using the support vector machine (SVM) show that, the optimized BRB can not only reduce the number of rules, but also achieve the highest modeling accuracy, and the effectiveness of the proposed method is verified.

Keywords: maritime based system; degradation analysis; prediction; belief rule base

0 引言

海基系统的性能退化是关系到海基系统可靠性评估和日常运转与维修的关键因素,直接影响海基系统的保障能力^[1].海基系统性能退化分析即对造成海基系统关键元器件、重要功能模块等损坏的因素进行分析,通过对退化因素的评级与分析,为确定海基系统的退化维修方案、增强保障能力以及提高海基系统的战斗力提供决策依据.因此,对海基系统性能

退化机理问题进行深入分析,对于进一步理解和掌握其性能退化规律,以及对其性能退化情况进行预测等方面具有理论和实际意义.

海基系统性能退化机理分析和预测需要考虑不确定条件下多种类型的信息来源,主要体现在3个方面^[2-3]:1)信息类型多样;2)信息不完整;3)人的参与导致信息不完整的情况进一步增加.而现有的评估方法(如专家调查法、仿真方法、混合方法等)在处理

收稿日期: 2017-09-10; 修回日期: 2018-04-18.

基金项目: 国家自然科学基金项目(71601180).

作者简介: 韩润繁(1993—),男,博士生,从事置信规则库、装备管理的研究;常雷雷(1985—),男,讲师,博士,从事置信规则库建模与优化等研究.

[†]通讯作者. E-mail: leileichang@hotmail.com.

不确定问题时效果欠佳,不能有效解决海基系统性能退化的评估问题。

置信规则库(BRB)^[4]是基于D-S证据理论提出的支持不确定条件下复杂系统建模、分析与评价的专家系统方法。该方法使用“IF-THEN”规则表示不确定和不完备条件下的专家经验与知识,以能够融合专家经验和历史数据等混合信息的证据推理算法为引擎,在处理复杂系统建模和评估问题时表现出特有的优势,并在系统行为识别与预测等诸多领域获得了应用。由于BRB可以较好地融合多种类型不确定信息,拟将其用于处理海基系统性能退化的评估问题。

在应用BRB解决实际问题时,BRB的复杂度随着问题规模的扩大呈现出指数增长的趋势。为了约减BRB中规则的数量,文献[5]首次提出了BRB结构学习方法,通过使用主成分分析、ISOMAP等技术筛选出BRB中关键前提属性,去掉非关键前提属性,进而简化BRB的复杂度;文献[6]采用 K 均值聚类法识别BRB结构,从而解决集约生产计划方面的系统控制问题;文献[7]提出了BRB动态优化方法,较大程度降低了BRB的复杂度。有关学者针对特定问题还提出了参数学习方法;文献[8]提出了BRB参数学习优化模型;文献[9]在处理输油管道泄露检测问题时使用参数优化模型,使问题得到了较好的解决。BRB结构学习降低了BRB的复杂度,但建模精度随之降低;参数学习提高了建模精度,但建立的模型复杂程度变大。因此,在处理海基系统性能退化这种既要求低复杂度又要求高精度的问题时,平衡BRB的结构学习和参数学习将在很大程度上有利于问题的解决。

本文针对海基系统性能退化不确定性强的特点,采用BRB参数与结构联合优化方法,建立双层优化的BRB最优决策结构模型,采用差分进化算法等方法对海基系统性能退化进行预测。该方法具有以下特性:1)能够融合各类不确定性信息,使得模型更加接近于海基系统的实际;2)平衡结构学习和参数学习对于BRB单方面的优化效果,使建立的模型复杂度低、精度高。

1 基于置信规则库专家系统的海基系统性能退化模型

海基系统性能退化评估可以回答退化因素如何影响退化程度的问题。海基系统性能退化评估本质上是信息综合集成与分析的过程,需要综合分析不确定条件下的多种类型信息。海基系统性能退化评估的输入是影响海基系统的退化因素,输出是海基系统的退化程度。

该评估问题具有以下两个显著特点:一方面影

响海基系统性能退化的因素种类多样,各因素变化难以预测,充满不确定性。同时,各因素变化具有随机性,使得一般的模型和方法难以准确评估海基系统性能退化程度。另一方面,海基系统性能退化评估需要专家参与。由于海基系统退化因素不确定性强,需要专家大量参与,现有的评估方法(如专家调查法、试验统计法、解析方法、仿真方法、混合方法)都不能较好地解决海基系统性能退化的评估问题。然而,BRB可以较好地融合不确定条件下的各种类型的信息,包括语义或数字、完备或不完备信息。同时,对于具有同样置信度结构的信息,采用证据推理算法可以将这些信息进一步综合集成,并以置信度等级的形式展示出综合集成的结果。因此,本文拟采用BRB解决海基系统性能退化评估问题,主要步骤如下。

Step 1: 构造BRB. BRB由“IF-THEN”规则组成,且每条规则的结论具有置信度结构。之所以在规则库中引入置信度的概念,是因为用置信度能很好地刻画规则的不确定性。带有置信度结构的海基系统BRB中的规则表示为

$$R_k: \text{if } A_1^k \wedge A_2^k \wedge \cdots \wedge A_{T_k}^k, \\ \text{then } \{(r_1, \beta_{1k}), (r_2, \beta_{2k}), \cdots, (r_L, \beta_{Lk})\}. \quad (1)$$

其中: $A_i^k (i = 1, 2, \cdots, T_k, k = 1, 2, \cdots, K)$ 表示在第 k 条规则中第 i 个前提属性的状态, T_k 表示第 k 条规则中前提属性的个数, K 表示置信规则库中规则的总条数; β_{lk} 表示前提条件成立时第 k 条规则第 l 个等级结论为 r_l 的置信度,且 $\sum_{l=1}^L \beta_{lk} \leq 1$ 。该条规则在

规则库中的相对权重记为 θ_k 。若 $\sum_{l=1}^L \beta_{lk} = 1$, 则该条

规则的信息是完全的, $\sum_{l=1}^L \beta_{lk} = 0$ 表示对输出结果一

无所知, $\sum_{l=1}^L \beta_{lk} \leq 1$ 表示对输出结果部分可知。

Step 2: 规则激活与权重计算. 海基系统BRB中各前提条件的参考值 A_{ij} 为 $\{A_{i1}, A_{i2}, \cdots, A_{i|A_i|}\}$, 不失一般性, 序列单调递增, 则有

$$w(x_i, A_{ij}) = \begin{cases} \frac{A_{i(k+1)} - x_i}{A_{i(k+1)} - A_{ik}}, & j = k (A_{ik} \leq x_i \leq A_{i(k+1)}); \\ \frac{x_i - A_{ik}}{A_{i(k+1)} - A_{ik}}, & j = k + 1; \\ 0, & j = 1, 2, \cdots, |A_i|, j \neq k, k + 1. \end{cases} \quad (2)$$

其中: A_{ij} 表示第 i 个前提属性的第 j 个参考值, $|A_i|$ 表示第 i 个前提属性参考值的个数.

特别地, 当规则中因素属性的取值为单点 A^* 时, 有

$$w(x_i, A_i^*) = 1 - \frac{|x_i - A_i^*|}{\max\{|A_i^* - p|, |q - A_i^*|\}}. \quad (3)$$

其中: x_i 为海基系统某项前提属性的实际值, $[p, q]$ 为 x_i 的实际取值区间, 这样定义的权重 w 可以保证: 当 $x_i = A_i^*$ 时, 函数 w 取值为 1, 且当 x_i 远离 A^* 时, 函数 w 递减.

Step 3: 使用证据推理算法进行集成, 解析公式^[10]为

$$\beta_l = \frac{\mu \left[\prod_{k=1}^K \left(w_k \beta_{lk} + 1 - w_k \sum_{l=1}^L \beta_{lk} \right) - \prod_{k=1}^K \left(1 - w_k \sum_{l=1}^L \beta_{lk} \right) \right]}{1 - \mu \left[\prod_{k=1}^K (1 - w_k) \right]}, \quad (4)$$

$$\mu = \left[\sum_{l=1}^L \prod_{k=1}^K \left(w_k \beta_{lk} + 1 - w_k \sum_{l=1}^L \beta_{lk} \right) - (L-1) \prod_{k=1}^K \left(1 - w_k \sum_{l=1}^L \beta_{lk} \right) \right]^{-1}. \quad (5)$$

2 面向最优决策结构的海基系统性能退化预测方法

2.1 结构学习的必要性

经过调研及论证, 总结出影响海基系统性能退化的 7 个因素包含: 故障装备、故障原因(机理)、问题性质、原因分类、换件/返厂/现场小修、从发现到解决时间差(天)、维修点是否在船上. 每个影响因素有 3 个取值, 其中, 维修点是否在船上有两个取值. 7 个前提属性生成的 BRB 规则数共有 2 187 条. 即使考虑简要情况(将 BRB 规则合并)也需要 730 条规则, 且每增加一个前提属性, BRB 的规则个数都呈现指数倍增长的趋势. 让专家给每一条规则逐一打分显然是不现实的. 因此, 需要通过结构学习筛选 BRB 中的关键前提属性, 以达到降低 BRB 规模的目的.

在建立 BRB 时, 当选择的前提属性中包括“维修点是否在船上”时, 由于该指标是离散的, 仅有两个取值“1”和“0”, 在计算规则数量时需要注意.

在表 1 中, “简要”指的是若任何一条规则中任一属性评价为“差”, 则该条规则的结论即评价为“差”.

表 1 BRB 规则数量

前提属性个数	BRB 规则数量(完整/简要)	
	3 个参考值	4 个参考值
2	8/5	16/10
3	27/9	64/17
4	81/28	256/65
5	243/82	1 024/257
6	729/244	4 096/1 025
7	2 187/730	16 384/4 097

2.2 基于主成分分析的置信规则库结构学习方法

针对置信规则库建模海基系统性能退化预测问题的特点以及组合爆炸问题, 采用基于主成分分析(PCA)的 BRB 结构学习方法^[5], 步骤如下:

- 1) 明确规则的初始结构参数;
- 2) 建立前提属性之间的关系;
- 3) 根据 PCA 方法寻找主要成分;
- 4) 反推出所需要的输入中的主要属性;
- 5) 建立结构学习后新的置信结构;
- 6) 生成与主要属性有关的所有规则;
- 7) 采用证据推理算法进行计算.

2.3 海基系统性能退化预测模型联合优化问题分析及建模

当采用 BRB 方法对海基系统性能退化预测问题建模时, BRB 的规模随着前提属性数量和前提属性参考值数量的增加而呈指数增加, 即当前前提属性数量过多或前提属性参考值过多时, 会导致 BRB 的组合爆炸问题, 因此需要通过减少前提属性数量或前提属性参考值数量约简 BRB 的规模, 这就要求进行 BRB 的结构学习. 同时, 采用 BRB(或者任何其他方法)建模、求解的最终目的都是要求模型能够最大程度逼近实际问题, 这就要求建模精度越高越好, 即要求模型与实际问题之间的误差越小越好, 因此需要进行 BRB 的参数学习^[11].

在当前 BRB 的相关研究中, BRB 的结构学习和参数学习均是分别进行的, 本文拟根据海基系统性能退化预测问题的特点, 建立 BRB 结构和参数联合优化模型, 并根据模型特点提出相应求解算法, 达到同时优化 BRB 结构和参数的目的.

将赤池信息准则(AIC)作为海基系统 BRB 联合优化模型的总目标^[12], 即外层优化目标, 决策变量为海基系统 BRB 规模(由各前提属性参考值数量决定); 由于 AIC 中包含模型精度(误差), 将均方差(MSE)作为海基系统优化模型的次要目标, 即内层优化目标, 决策变量是海基系统 BRB 中的前提属性. 综上, 建

立的海基系统BRB结构和参数联合优化模型中,外层优化模型结构(BRB规模)和内层优化模型参数(BRB精度)分别为

$$\text{AIC}_{\text{BRB}} = P \ln(P \times \text{MSE}) + 2N, \quad (6)$$

$$\text{MSE} = \frac{1}{K} \sum_{k=1}^K (U(D_l)(\beta_{lk} - \hat{\beta}_{lk}))^2. \quad (7)$$

双层模型为

$$\begin{aligned} & \min \text{AIC}_{\text{BRB}}(\text{num}), \\ & \min \text{MSE}(v(\text{num})). \end{aligned} \quad (8)$$

内层优化模型为

$$\min \text{MSE}(x, \theta, \beta); \quad (9)$$

$$\text{s.t. } lb_i \leq x_i^k \leq ub_i, \quad (10)$$

$$x_i^1 = lb_i, \quad (11)$$

$$x_i^K = ub_i, \quad (12)$$

$$0 < \theta_k \leq 1, \quad (13)$$

$$0 \leq \beta_{lk} \leq 1, \quad (14)$$

$$\sum_{l=1}^L \beta_{lk} \leq 1. \quad (15)$$

其中 $l = 1, 2, \dots, L$ 表示等级结论的个数. 式(10)表示海基系统各前提属性参考值的取值范围要介于其上下限之间; 式(11)和(12)表示海基系统前提属性参考值的上下限取值分别应为其上下限值; 式(13)表示海基系统各条规则的初始权重应介于0与1之间; 式(14)表示海基系统各条规则中结论部分各等级的置信度值应介于0与1之间; 式(15)表示各规则中结论部分各等级的置信度值之和应小于等于1(当存在不完备信息时, $\sum_{l=1}^L \beta_{lk} \leq 1$, 否则 $\sum_{l=1}^L \beta_{lk} = 1$).

外层优化模型的优化目标是 AIC_{BRB} , 决策变量是海基系统各前提属性的参考值数量. 外层优化模型为

$$\min \text{AIC}_{\text{BRB}}(\text{num}); \quad (16)$$

$$\min(A_i) \leq A_i \leq \max(A_i), i \in [1, 2, \dots, M]. \quad (17)$$

其中 $\min(A_i)$ 和 $\max(A_i)$ 分别表示海基系统第 i 个前提属性参考值的最小和最大值.

2.4 基于双层优化的置信规则库最优决策结构模型求解方法

2.4.1 内层优化模型求解算法

模型采用差分进化算法^[11]作为内层模型的优化引擎,其他优化算法可视具体问题特征选用或作为对

比算法酌情采用.

Step 1: 参数初始化. 内层算法参数主要包括海基系统BRB和差分进化算法的相关参数,需要注意的是各参数是在海基系统BRB规模确定(海基系统各前提属性参考值的个数确定)的前提下进行初始化的.

Step 2: 优化操作. 交叉操作如下:

$$v = \begin{cases} z_1, & \text{rand} \leq \text{CR or } j = \text{sn}; \\ z_2, & \text{Otherwise.} \end{cases} \quad (18)$$

其中: CR为交叉算子, sn为随每个个体产生的随机整数, v 为进入下一代的个体, z_1 和 z_2 为两个随机个体.

变异操作如下:

$$v = z_1 + F \times (z_2 - z_3). \quad (19)$$

其中: z_1 、 z_2 和 z_3 为3个随机个体,且 $z_1 \neq z_2 \neq z_3$, $F = 0.5$ 为变异算子.

Step 3: 适应度函数计算.

1) 规则激活、匹配度计算与权重计算.

2) ER推理,详见式(4)和(5).

3) 结果输出. 输出结果为

$$T = \sum_{l=1}^L U(D_l) \beta_l. \quad (20)$$

Step 4: 选择操作

$$z_i^{t+1} = \begin{cases} u_i^t, & f(u_i^t) \leq f(z_i^t); \\ z_i^t, & \text{Otherwise.} \end{cases} \quad (21)$$

其中: $f(\cdot)$ 为适应度函数, z^t 为第 t 代随机个体, z^{t+1} 为第 $t+1$ 代随机个体.

Step 5: 检查终止条件. 当达到终止条件(一般为初始设定的终止代数)时,终止优化程序,此时具有最小MSE的个体为最优个体;否则返回Step 3.

2.4.2 外层优化模型求解算法

Step 1: 初始化. 外层优化模型的初始化参数为海基系统各前提属性的参考值数量.

Step 2: 进行内层优化.

Step 3: 计算 AIC_{BRB} .

Step 4: 检查 AIC_{BRB} 是否达到终止条件.

对于海基系统第 i 个前提属性,有

if $A_i > A_{i,\text{ini}}$

Compare $\text{AIC}_{\text{BRB}}(i, A_{i-1})$ with $\text{AIC}_{\text{BRB}}(i, A_i)$;

if $\text{AIC}_{\text{BRB}}(i, A_{i-1}) < \text{AIC}_{\text{BRB}}(i, A_i)$

stop;

```
end
else
    go to Step 6;
end

Step 5: 检查终止条件. 终止条件一般为设定的
代数. 对于第i个前提属性, 需要进行如下操作:

    if  $A_i = A_{i, \max}$ 
        stop;
    else
        go to Step 6;
    end
```

Step 6: 搜索优化路径. 根据优化路径搜索策略搜索优化路径, 具体步骤见下节.

2.4.3 优化路径搜索策略

Step 1: 选择海基系统第*i*个前提属性, 并保持其他前提属性不变.

Step 2: 对于选择的第*i*个前提属性, 随机选择其两个相邻参考值.

Step 3: 局部优化. 与 2.4.1 节的内层优化模型求解算法相同.

Step 4: 计算 $AIC_{BRB}(\text{num})$.

Step 5: 筛选下一个前提属性, 并重复 Step 2 ~ Step 4, 直至完成全部前提属性的优化为止.

Step 6: 在完成 Step 1 ~ Step 5 之后, 对比不同的 $AIC_{BRB}(\text{num})$, 假设存在两个前提属性 *m* 和 *q*, 则有

Compare $AIC_{BRB}((i, A_i), (q, A_q))$ with $AIC_{BRB}((i, A_{i+1}), (q, A_q)), AIC_{BRB}((i, A_m), (q, A_{q+1}))$

if $AIC_{BRB}((i, A_{m+1}), (q, A_q))$ is the smallest

the *i* th attribute is the optimization direction

```
else
    if  $AIC_{BRB}((i, A_i), (q, A_{q+1}))$  is the smallest
        the q th attribute is the optimization direction
    else
        if  $AIC_{BRB}((i, A_i), (q, A_q))$  is the smallest
             $(i, A_i), (q, A_q)$  is the optimal solution
        end
    end
end
```

Step 7: 判断是否达到终止准则. 若取得 AIC_{BRB} 的较优解, 则终止; 否则, 返回 Step 3, 继续进行优化.

3 基于海基系统性能退化预测的实例分析

3.1 基于主成分分析的置信规则库优化

使用 SPSS 软件, 采用主成分分析方法筛选关键前提属性. 当选取特征值大于 1 的主成分时, 有两个主要成分符合要求, 此时故障装备、问题性质、从发现到解决时间差 3 个因素比较突出, 但此时仅能累积覆盖 72.918 % 的信息; 当选累积覆盖超过 80 % 信息的主成分时, 前 3 个主要成分才能符合要求, 此时, 故障装备、故障原因、原因分类、从发现到解决时间差 4 个因素比较突出.

表 2 和表 3 分别给出了采用基于主成分分析的结构学习之后获得的具有 3 个和 4 个前提属性的 BRB (分别称为 BRB-3 和 BRB-4).

为了进一步降低 BRB 规模, 将多条结论一致的规则合并为一条规则: 多个指标中当存在任一属性取得最大值时, 严重程度为“严重”.

表 2 和表 3 所示的 BRB 得到的估计结果与实际结果如图 1 和表 4 所示.

表 2 具有 3 个前提属性的 BRB-3

序号	权重	前提属性			结论等级		
		故障装备	问题性质	从发现到解决时间差	较轻	较重	严重
1	1	0.1	0.1	1	0.835 6	0.158 7	0.005 7
2	1	0.1	0.1	0.43	0.478 1	0.378 2	0.143 7
3	1	0.1	0.4	1	0.273 6	0.128 3	0.598 1
4	1	0.1	0.4	0.43	0.527 1	0.182 7	0.290 2
5	1	0.3	0.1	1	0.362 8	0.238 1	0.399 1
6	1	0.3	0.1	0.43	0.028 3	0.372 8	0.598 9
7	1	0.3	0.4	1	0.182 1	0.329 1	0.488 8
8	1	0.3	0.4	0.43	0.362 1	0.312 3	0.325 6
9	1	故障装备 = “1” ∨ 问题性质 = “1” ∨ 时间差 = “1”			0	0	1

表3 具有4个前提属性的BRB-4

序号	权重	前提属性				结论等级		
		故障装备	故障原因	原因分类	从发现到解决时间差	较轻	较重	严重
1	1	0.1	0.1	0.1	1	0.814 1	0.099 6	0.086 3
2	1	0.1	0.1	0.1	0.43	0.691 4	0.153 7	0.154 8
3	1	0.1	0.1	0.6	1	0.714 1	0.099 6	0.186 3
4	1	0.1	0.1	0.6	0.43	0.691 4	0.153 7	0.154 8
5	1	0.1	0.4	0.1	1	0.523 1	0.089 5	0.387 4
6	1	0.1	0.4	0.1	0.43	0.726 0	0.106 9	0.167 1
7	1	0.1	0.4	0.6	1	0.523 1	0.089 5	0.387 4
8	1	0.1	0.4	0.6	0.43	0.726 0	0.106 9	0.167 1
9	1	0.3	0.1	0.1	1	0.602 3	0.122 0	0.275 7
10	1	0.3	0.1	0.1	0.43	0.168 2	0.152 6	0.679 1
11	1	0.3	0.1	0.6	1	0.426 7	0.143 4	0.429 9
12	1	0.3	0.1	0.6	0.43	0.601 7	0.139 7	0.258 5
13	1	0.3	0.4	0.1	1	0.602 3	0.122 0	0.275 7
14	1	0.3	0.4	0.1	0.43	0.168 2	0.152 6	0.679 1
15	1	0.3	0.4	0.6	1	0.426 7	0.143 4	0.429 9
16	1	0.3	0.4	0.6	0.43	0.633 3	0.139 7	0.258 5
17	1	故障装备 = “1” ∨ 故障原因 = “1” ∨ 原因分类 = “1” ∨ 时间差 = “1”				0	0	1




图1 结构学习后的BRB-3/4对比(基于主成分分析)

表4 具有最优决策结构的BRB模型预测结果对比

序号	模型	规则数量	错误数量	正确率/%
1	BRB-3	9	7	79.41
2	BRB-4	17	3	91.18

从图1和表4的对比可知, BRB-4所得结果更优,

这是由于其中规则数量更多, 模型更加复杂.

3.2 基于最优决策结构的置信规则库优化

根据2.3节建立的BRB双层优化模型和2.4节提出的求解算法, 随机选取50%数据作为训练数据, 全部数据为验证数据并进行30次实验, 分别得到如表5(3个前提属性、4条规则)、表6(4个前提属性、4条规则)和表7(4个前提属性、5条规则)所示的BRB. 图2和表8给出了表5~表7中BRB模型输出与实际输出的对比. 由图2和表8可知, 具有4个前提属性和5条规则的BRB即可实现100%的建模精度. 这说明采用2.3节提出的BRB最优决策模型建模方法和2.4节提出的模型求解方法不仅可以同时优化BRB的结构和参数, 而且在理论方面该方法还具有先进性.

表5 具有3个前提属性的BRB-3(4条规则)

序号	权重	前提属性			结论等级		
		故障装备	问题性质	从发现到解决时间差	好	中	差
1	0.550 6	0.100 0	0.100 0	0.010 0	0.419 1	0.339 7	0.241 2
2	0.383 3	0.593 0	0.685 3	0.032 8	0.432 0	0.337 0	0.231 0
3	0.294 2	0.596 8	0.362 1	0.161 8	0.287 1	0.519 5	0.193 4
4	0.998 1	1.000 0	1.000 0	1.000 0	0.071 0	0.401 7	0.527 3

表6 具有4个前提属性的BRB-4(4条规则)

序号	权重	前提属性				结论等级		
		故障装备	故障原因	原因分类	从发现到解决时间差	好	中	差
1	0.837 9	0.100 0	0.100 0	0.100 0	0.010 0	0.517 6	0.355 8	0.126 5
2	0.071 0	0.674 7	0.745 1	0.345 3	0.686 6	0.222 9	0.343 0	0.434 1
3	0.744 9	0.906 9	0.831 5	0.345 2	0.144 5	0.010 3	0.522 7	0.467 0
4	0.308 6	1.000 0	1.000 0	1.000 0	1.000 0	0.048 2	0.076 6	0.875 2

表 7 具有4个前提属性的BRB-4(5条规则)

序号	权重	前提属性				结论等级		
		故障装备	故障原因	原因分类	从发现到解决时间差	好	中	差
1	0.339 7	0.100 0	0.100 0	0.100 0	0.010 0	0.858 8	0.100 8	0.040 4
2	0.216 4	0.303 5	0.730 0	0.624 8	0.125 8	0.708 8	0.036 0	0.255 3
3	0.577 5	0.890 9	0.364 9	0.400 9	0.158 5	0.108 2	0.704 3	0.187 6
4	0.993 5	0.968 4	0.895 6	0.536 2	0.432 9	0.025 7	0.339 1	0.635 2
5	0.141 4	1.000 0	1.000 0	1.000 0	1.000 0	0.223 4	0.056 0	0.720 6




图 2 经过结构学习后的BRB-3/4结果对比

表 8 BRB与支持向量机结果对比

序号	模型	错误数量	正确率/%
1	BRB-3(4条规则)	2	94.12
2	BRB-4(4条规则)	1	97.06
3	BRB-4(5条规则)	0	100

同时与3.1节得到的模型分析结果(表2和表3)相比,采用具有最优决策结构的BRB进行建模不仅可以大大降低模型中规则的数量(从9条和17条规则降低至4条和5条规则),同时,模型的精度也有了较大的提高(从79.41%和91.18%分别提高至94.12%、97.06%和100%),验证了本文提出的具有BRB最优决策结构的海基系统性能退化预测方法的有效性。

3.3 置信规则库与支持向量机结果对比

采用支持向量机(SVM)^[13]进行对比分析。SVM的相关参数设置为 $\Gamma=5\,000$, $\sigma^2=80$,并进行30次实验。表9给出了BRB与SVM的结果对比。

表 9 BRB与支持向量机结果对比

方法	错误数量最小结果	正确率/%	结果均值	结果方差
BRB	0	100	0.533 3	0.395 4
SVM	0	100	0.766 7	2.736 8

由表9两种方法的结果对比可知,SVM与BRB均能得到错误数量最小的结果、正确率、均值和方差。首先,两种方法均能够100%识别出测试数据的严重程度。但是相比而言,BRB计算得到的错误数量均值0.5333小于支持向量机计算得到的错误数量均值0.7667,且BRB计算得到的错误值方差0.3954

小于支持向量机计算得到的错误值方差2.7368。因此,BRB得到的结果可信性更强(均值更低),稳定性更高(方差较小)。

3.4 结果分析

采用双层优化的BRB最优决策结构可以融合多源不确定信息,比一般的分析方法更加适用于处理具有多种不确定信息的海基系统。

双层优化结构可以弥补单方面采用主成分分析造成的海基系统BRB精度不足的问题,将BRB-3的正确率由79.41%提高到了94.12%,BRB-4的正确率由91.18%提高到了97.06%,使得预测精度具有很大的提高。原因是:当采用双层优化模型时,由于内层模型MSE的约束限制以及采用差分进化算法作为内层模型的优化引擎,在生成规则库时权衡了规模和精度两方面的要求,使得综合优化效果高于单方面优化效果。

另外,在海基系统性能退化问题以4条规则为基础建模时,筛选的故障装备、问题性质和从发现到解决时间差等3个前提属性提升至故障装备、故障原因、原因分类和从发现到解决时间差等4个前提属性。这说明,“故障装备”和“从发现到解决时间差”两个指标与海基系统性能退化问题建模相关性较强。同时正确率由94.12%提升至97.06%;当规则库数量由4条提升至5条后,正确率由97.06%提升至100%。这说明增加模型复杂度能够有效改进海基系统性能退化问题建模的精度。

采用BRB进行建模和求解另一大优势在于,BRB是一个白箱系统,其建模过程和模型推理过程都是可见的,专家可参与,结果的可解释性较好^[5,8-10]。采用其他方法(如SVM),虽然也可以取得较好效果,但是其模型大多为黑箱系统,模型不可见,结果的可解释性相对较差。

4 结 论

海基系统性能退化预测问题具有较强的不确定性,本文提出采用BRB参数与结构联合优化方法,通

过得到双层优化BRB最优决策结构模型处理海基系统的不确定条件下的多种类型信息. 对比模型输出和实际输出,发现采用最优决策结构的BRB建模方法不仅可以降低模型中规则的数量,也提高了模型精度,使得模型更加接近于海基系统退化的真实情况,为退化机理分析与预测提供了强有力的技术支撑. 对于掌握海基系统的性能退化规律、提高海基系统的生存能力具有实际意义.

参考文献(References)

- [1] 熊奇, 韩润繁, 陈桂明, 等. 海基系统性能退化及影响因素分析[C]. 第四届飞行器海基测量与应用学术年会. 江阴: 国防大学, 2016: 22-28.
(Xiong Q, Han R F, Chen G M, et al. The performance degradation and influencing factors of the sea based system[C]. The 4th Academic Annual Meeting of the Sea Based Aircraft Measurement and Application. Jiangyin: National Defense University Press, Jiangyin: National Defense University, 2016: 22-28.)
- [2] 袁容. 基于性能退化分析的可靠性方法研究[D]. 成都: 电子科技大学机械与电气工程学院, 2015: 8-12.
(Yuan R. Research on reliability modeling and analysis methods based on the performance degradation[D]. Chengdu: School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, 2015: 8-12.)
- [3] 赵建印. 基于性能退化数据的可靠性建模与应用研究[D]. 长沙: 国防科学技术大学机电工程与自动化学院, 2005: 18-24.
(Zhao J Y. Study on reliability modeling and applications based on performance degradation[D]. Changsha: College of Mechanical and Electrical Engineering and Automation, National University of Defense Technology, 2005: 18-24.)
- [4] 庞煜. 基于可能性理论和格论的系统可靠性分析[D]. 成都: 电子科技大学, 2012: 30-34.
(Pang Y. System reliability analysis based on possibility theory and lattice theory[D]. Chengdu: University of Electronic Science and Technology of China, 2012: 30-34.)
- [5] Chang L L, Zhou Y, Jiang J, et al. Structure learning for belief rule base expert system: A comparative study[J]. Knowledge-Based Systems, 2013, 39(2): 159-172.
- [6] Li B, Wang H W, Yang J B, et al. A belief K -means clustering algorithm for structure identification of belief-rule-base[J]. Systems Engineering, 2011, 22(5): 85-91.
- [7] Wang Y M, Yang L H, Fu Y G, et al. Dynamic rule adjustment approach for optimizing belief rule-base expert system[J]. Knowledge-Based Systems, 2016, 32(96): 40-60.
- [8] Yang J B, Liu J, Xu D L, et al. Optimization models for training belief-rule-based systems[J]. IEEE Trans on Systems, Man, and Cybernetics-Part A: Systems and Humans, 2007, 37(4): 569-585.
- [9] Xu D L, Liu J, Yang J B, et al. Inference and learning methodology of belief-rule-based expert system for pipeline leak detection[J]. Expert Systems with Applications, 2007, 32(1): 103-113.
- [10] Wang Y M, Yang J B, Xu D L, et al. Environmental impact assessment using the evidential reasoning approach[J]. European J of Operational Research, 2006, 174(3): 1885-1913.
- [11] Chang L L, Sun J B, Jiang J, et al. Parameter learning for the belief rule base system in the residual life probability prediction of metalized film capacitor[J]. Knowledge-Based Systems, 2015, 73(3): 69-80.
- [12] Chang L L, Wang L Y, Wang W, et al. Akaike information criterion-based objective for belief rule base optimization[C]. The 8th Int Conf on Intelligent Human Machine Systems and Cybernetics. Hangzhou: IEEE, 2016: 545-549.
- [13] Samanta B, Al-Balushi K R, Al-Araimi S A. Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection[J]. Engineering Applications and Artificial Intelligence, 2003, 23(16): 657-665.

(责任编辑: 闫妍)