

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20221086

基于贝叶斯网络的水轮机故障诊断研究

孙少楠, 李博宇, 聂相田

(华北水利水电大学水利学院, 河南 郑州 450000)

摘要: 为解决水轮机故障诊断过度依赖专家经验且效率低的现状, 利用水轮机故障历史数据和相关专家经验, 建立故障树模型, 寻求风险隐患和故障诊断之间的映射, 通过故障树模型和贝叶斯网络模型的转换, 利用贝叶斯网络的反向诊断技术深入研究根节点的概率重要度和敏感性, 推理出导致故障发生的水轮机部件及故障原因, 实现对水轮机的故障诊断。

关键词: 贝叶斯网络; 故障诊断; 故障树; 敏感性分析

中图分类号: [TV734. 2⁺. 1]; TM312

文献标志码: A

文章编号: 1000-7709(2023)03-0190-05

1 引言

水轮发电机组是水电站运维管理的关键, 水轮机的故障诊断存在故障机理复杂、故障多态和逻辑模糊不确定的特点, 采用传统诊断方式很难直接分析出故障原因。与传统的故障诊断方法相比, 贝叶斯网络能更好地融合概率论和图形可视化, 适用于解决系统复杂多态、信息模糊、逻辑不确定的复杂问题。现阶段贝叶斯网络在故障诊断、风险预估等研究领域均应用广泛。由此引入贝叶斯网络模型分析, 李俭川等^[1]提出利用贝叶斯网络理论进行设备故障诊断; 周忠宝等^[2]将多态故障树和贝叶斯网络融合进行故障诊断; 于劲松等^[3]采用准确度和置信区间相结合的方式, 实现贝叶斯网络故障诊断评价优化。因此, 为解决水轮机故障诊断过度依赖专家经验且效率低的现状, 通过深度挖掘的历史故障数据及专家意见, 构建故障树模型, 通过故障树模型和贝叶斯网络模型的转换, 利用贝叶斯网络的反向诊断技术, 深入研究根节点的概率重要度和敏感性, 实现了对水轮机的故障诊断。

2 构建故障树

以混流式水轮机为例, 通过剖析水轮机的基

本组成部件、深度挖掘水轮机历史故障数据、查阅相关文献及大量相关工程实践经验, 总结分析水轮机故障发生的风险机理, 构建具有相对通用性, 且适用于反击式水轮机进行故障诊断分析的水轮机故障树。将主轴及密封、导水机构、过流部件、转轮、水导轴承故障系统作为中间事件进行着重考虑, 拓展研究各层级的底事件, 形成底事件的故障节点编号集合 $X = \{X_1, X_2, \dots, X_{32}\}$, 结合水轮机的故障多态性和故障原因模糊性的特点, 选择使用逻辑“或”门进行基础底事件的逻辑表达。形成的故障树见图 1, 相对应的编号内容及故障名称见表 1。




图 1 水轮机故障树
Fig. 1 Turbine fault tree

3 基于贝叶斯网络的故障预测模型

贝叶斯网络模型(BN)由有向无环图(DAG)和条件概率表(CPT)构成, 从节点影响角度分为

收稿日期: 2022-05-22, 修回日期: 2022-08-06

基金项目: “新基建”项目(2020JGLX045); 国家自然科学基金资助项目(72271091, 51709115); 河南省重点研发与推广专项(科技攻关)项目(182102210066)

作者简介: 孙少楠(1974-), 男, 博士、副教授, 研究方向为 BIM 技术、水利工程施工组织与管理, E-mail: ncwussn@163.com

X_2, \dots, X_n 为各底层故障因子,叶节点 T 为水轮机故障,后验概率就是叶节点发生的前提下根节点 X_i 随机发生的概率,参考根节点先验概率后,通过贝叶斯理论公式获得 X_i 后验概率:

$$P(X_i | T) = \frac{P(T | X_i)P(X_i)}{\sum_{i=1}^n P[(T | X_i)P(X_i)]} \quad (4)$$

式中, $P(X_i)$ 为先验概率; $P(X_i | T)$ 为后验概率,为 T 发生时 X_i 发生的概率; $P(T | X_i)$ 为条件概率,为 X_i 发生时 T 发生的概率。

因此以底事件 X_1 (密封外冷却水流量低报警) 为例,通过贝叶斯理论公式,实现后验概率的求取。即:

$$\begin{cases} P(M_1 | T) = P(M_1)P(T | M_1)/P(T) \\ P(H_1 | T) = P(H_1 | M_1)P(M | T) \\ P(X_1 | T) = P(X_1 | H_1)P(H_1 | T) \end{cases} \quad (5)$$

3.2 贝叶斯网络诊断

贝叶斯网络诊断是从故障结果向故障原因进行反向推断,利用贝叶斯网络的反向诊断能力获取根节点的后验概率。此外通过研究根节点的结构重要度和敏感度弥补后验概率单一指导故障分析的不足。综合研究根节点结构重要度,能够直观了解底事件的事件变化对叶节点的影响,利于研究水轮机的薄弱环节,参考贝叶斯基本原理(式(4)),定义根节点 X_i 的状态 C_1 (发生故障时 $C_1=1$,正常运行时 $C_1=0$), $P_a(X_i)$ 为 X_i 的根节点条件概率,当 X_i 的状态为 C_1 时的概率:

$$P(X_i = C_1) = \sum_{i=1}^n P\{X_i = C_1 | P(X_i)P_a(X_i)\} \quad (6)$$

叶节点 T 的状态为 C_2 (发生故障时 $C_2=1$,正常运行时 $C_2=0$) 时的概率:

$$P(T = C_2) = P(T = C_2 | X_1, X_2, \dots, X_n) \prod_{i=1}^n P(X_i) \quad (7)$$

当根节点的状态为 C_1 时,影响的叶节点状态 C_2 的结构重要度为:

$$I_{Tq}^{Pr}(X_i = C_1) = \frac{P(T = C_2 | X_i = C_1) - P(T = C_2 | X_i = 0)}{\quad} \quad (8)$$

由式(6)~(8)可推断出当叶节点状态为 C_2 时根节点 X_i 的结构重要度:

$$I_{Tq}^{Pr}(X_i) = \frac{1}{m-1} \sum_{i=1}^n I_{Tq}^{Pr}(X_i = C_1) \quad (9)$$

区别于根节点的结构重要度的定性分析,引入 R_{ROV} 的概念,即:

$$R_{ROV}(X_i) = \frac{P(X_i = C_1 | T = C_1) - P(X_i = C_1)}{P(X_i = C_1)} \quad (10)$$

通过比较各根节点间后验概率和先验概率的差值相对于先验概率的比值斜率,进行根节点影响程度的定量分析。

根节点的灵敏度用于描述根节点对叶节点的影响程度,根据其敏感性分析可推断出根节点故障对叶节点的影响程度,当某根节点的敏感度高时,说明该根节点对叶节点的影响程度大且可靠性高:

$$S_{Tq}^{(l)}(X_i = C_1) = \frac{I_{Tq}^{Pr}(X_i = C_1)}{P(T = C_2 | X_i = 0)} \quad (11)$$

$$S_{Tq}^{(l)}(X_i = C_1) = \frac{1}{m-1} \sum_{i=1}^n S_{Tq}^{(l)}(X_i = C_1) \quad (12)$$

式中, $S_{Tq}^{(l)}(X_i = C_1)$ 为根节点状态 $X_i = C_1$ 时的叶节点故障状态,由此可推导出 $S_{Tq}^{(l)}(X_i)$ 为根节点对叶节点的敏感度。

4 算例分析

4.1 贝叶斯网络反向诊断

利用 GeNIe 贝叶斯故障分析软件进行贝叶斯网络模型的参数分析和故障诊断推理,定义根节点 X_i 的故障节点状态 $S = \{Alarm, Normal\}$, Alarm 表示水轮机部件的故障警告, Normal 表示正常运行,以底事件 $X_7 \sim X_{13}$ 作为算例,通过调查历史故障数据,沟通专业技术人员,统计各根节点模糊程度的上下限 (n_i, u_i) 及置信中值 m_i , 获取模糊概率,并代入 GeNIe 作为各根节点的先验概率。运用式(4)~(10)可得相应根节点的后验概率及 R_{ROV} , 经 GeNIe 的数据优化及统计 R_{ROV} 的定量分析,获取根节点 $X_7 \sim X_{13}$ 对叶节点 T 在不同节点状态下的影响程度排序,见表 2。

表 2 后验概率及 R_{ROV} 排序分布

Tab. 2 Posterior probability and R_{ROV} ranking distribution

R_{ROV} 排序	根节点	先验概率		后验概率		R_{ROV}
		Normal	Alarm	Normal	Alarm	
1	X_{12}	0.890 1	0.109 9	0.78	0.22	1.002 0
2	X_8	0.880 2	0.119 8	0.86	0.14	0.168 6
3	X_{13}	0.917 7	0.082 3	0.91	0.09	0.093 6
4	X_{11}	0.881 1	0.118 9	0.87	0.13	0.093 4
5	X_{10}	0.770 7	0.229 3	0.75	0.25	0.090 3
6	X_7	0.829 7	0.170 3	0.82	0.18	0.057 0
7	X_9	0.948 2	0.051 8	0.95	0.05	0.034 7

由表 2 可知,综合考虑后验概率及 R_{ROV} 的数值,剪断销剪断 X_{12} 故障对导叶故障影响最大,因此在导水机构失效的情况下,应优先对给剪断

销进行失效检修排查,再根据 R_{ROV} 影响程度依次排查,进而缩短故障排查时间,提升故障诊断的准确性和可靠性。由此搭建水轮机故障的贝叶斯网络参数模型见图 4,利用贝叶斯网络的反向推理诊断,即当叶节点水轮机故障 $T = Alarm$ (信号警告)发生概率为 100%时,通过 GeNIe 内嵌算法可得贝叶斯网络反向推理诊断见图 5,按照故障警告的影响程度进行故障排序,从大到小依次为导水机构、主轴及密封、水导轴承、转轮和过流部件。

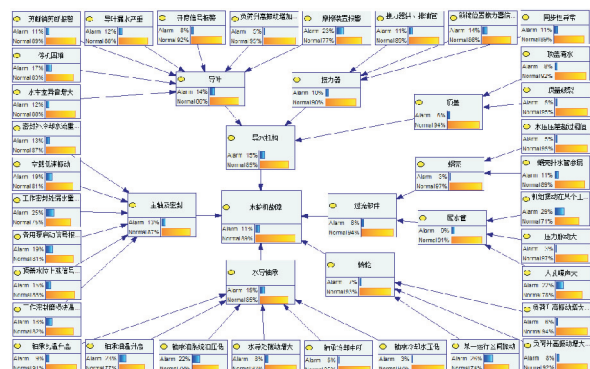


图 4 水轮机故障贝叶斯网络参数学习

Fig. 4 Parameter learning of bayesian network for turbine failure

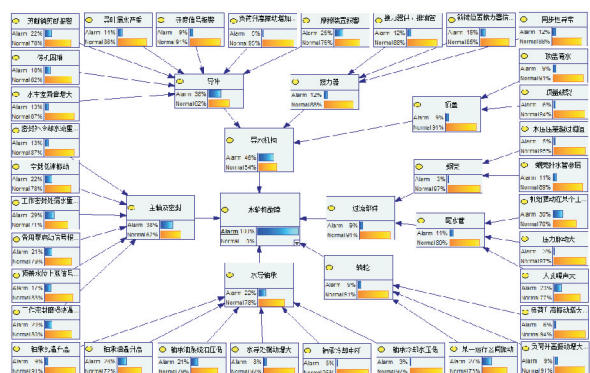


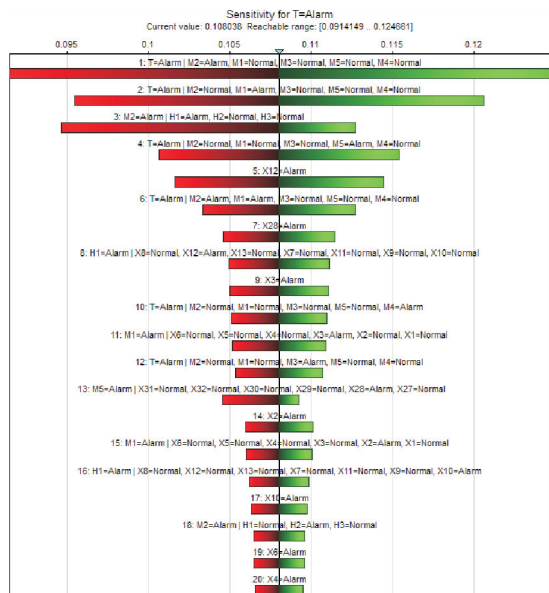
图 5 水轮机故障贝叶斯网络反向推理

Fig. 5 Reverse inference of turbine fault bayesian network

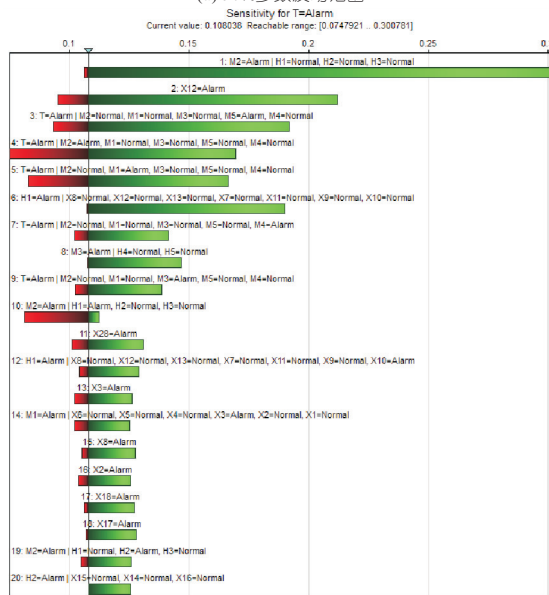
4.2 贝叶斯诊断敏感性分析

通过对水轮机贝叶斯网络诊断模型的根节点进行敏感度分析,获取根节点网络参数的改变对叶节点输出概率的影响程度。将 $T = Alarm$ 作水轮机故障的敏感性分析目标,分别设置参数波动范围为 50%、100%,最大程度且较为明确的体现不同根节点对叶节点的敏感性差异,见图 6。由图 6 可看出,前 20 项影响节点中,单根节点 X_{12} 对叶节点 $T = Alarm$ 时的影响程度最大。其次是 X_{28} 、 X_3 、 X_8 的敏感度较高。

同时,利用 Sensitivity Analysis 算法对水轮机的故障根节点进行敏感性分析,见图 7。将敏感性龙卷风图的定量分析转化为能够直观分析的敏感性分析图,图 7 中的根节点颜色越深,则表明



(a) 50%参数波动范围



(b) 100%参数波动范围

图 6 50%、100%参数波动范围的敏感性分析龙卷风图
Fig. 6 Sensitivity analysis tornado chart for 50% and 100% parameter fluctuation range

相应根节点的变化对叶节点的影响程度越高,即表示其敏感性越大。由图 7 可知,导水机构故障

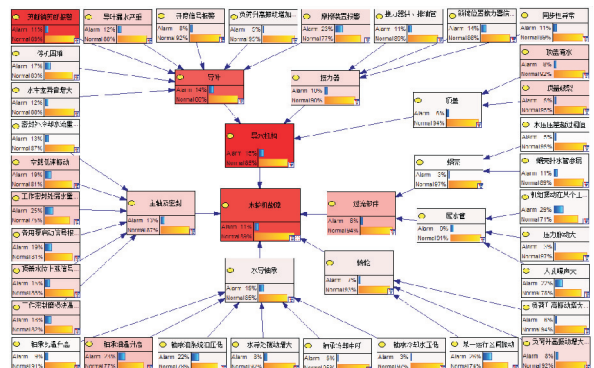


图 7 贝叶斯网络敏感性分析

Fig. 7 Bayesian network sensitivity analysis

的敏感性最高,转轮故障的敏感性最低,在水导轴承故障的敏感性分析中,轴承温升影响较大。针对导水机构故障、中间节点导叶故障的敏感性影响远高于接力器故障和顶盖故障,且导叶故障中剪断销剪断的敏感性最高,其次为导叶漏水严重、开度信号报警和摩擦装置报警。水轮机故障的贝叶斯网络模型得出的数据和实际故障影响程度较为相符,具有可参考性。

5 结 论

a. 为解决水轮机故障诊断过度依赖专家经验且效率低的现状,构建了水轮机故障的故障树模型,将故障树模型与贝叶斯网络模型形成映射,利用贝叶斯网络模型的反向诊断技术实现故障诊断和定位,并将故障诊断以概率量化的形式体现。

通过敏感性分析获取根节点对叶节点的影响程度,提升了贝叶斯网络模型诊断的准确性,为检修工作人员提供了参考意见。

b. 现阶段仅在水轮机故障诊断中应用了贝叶斯网络诊断模型,未来应进行多元耦合的贝叶斯故障诊断。

参 考 文 献:

[1] 李俊川,胡葛庆,秦国军,等. 贝叶斯网络理论及其在设备故障诊断中的应用[J]. 中国机械工程,2003(10):92-96,6.

[2] 周忠宝,马超群,周经伦,等. 基于贝叶斯网络的多态故障树分析方法[J]. 数学的实践与认识,2008(19):89-95.

[3] 于劲松,沈琳,唐获音,等. 基于贝叶斯网络的故障诊断系统性能评价[J]. 北京航空航天大学学报,2016,42(1):35-40.

Research on Fault Diagnosis of Hydraulic Turbine Based on Bayesian Network

SUN Shao-nan, LI Bo-yu, NIE Xiang-tian

(School of Water Conservancy, North China University of Water Resources and Electric Power, Zhengzhou 450000, China)

Abstract: In order to solve the current situation that hydraulic turbine fault diagnosis relies excessively on expert experience and has low efficiency, the historical data of hydraulic turbine fault and relevant expert experience were used to establish the fault tree model for seeking the mapping between risk hidden danger and fault diagnosis. Through the conversion of fault tree model and Bayesian network model, the probability importance and sensitivity of root node were deeply studied by using the reverse diagnosis technology of Bayesian network. Hydraulic turbine components and fault causes were inferred to realize the fault diagnosis.

Key words: Bayesian networks; fault diagnosis; fault trees; sensitivity analysis

(上接第 197 页)

参 考 文 献:

[1] 杜义,周建中,单亚辉,等. 基于 EMD-BPNN 的水电机组空蚀故障诊断[J]. 水电能源科学,2018,36(3):157-160.

[2] 杨彤,王卫玉,张培,等. 基于 CEEMDAN 和混合灰狼算法优化 SVM 的水电机组故障诊断方法[J]. 水电能源科学,2022,40(3):195-198.

[3] 刘涵. 水电机组多源信息故障诊断及状态趋势预测方法研究[D]. 武汉:华中科技大学,2019.

[4] YEWANG CHEN, XIAOLIANG HU, WENTAO FAN, et al. Fast density peak clustering for large scale data based on kNN[J]. Knowledge-based systems, 2020,187:104824.

[5] HE Z C, QIU Y, LI E, et al. Analysis on loudness of exhaust noise and improvement of exhaust system based on structure-loudness mode[J]. Applied acoustics, 2019,105:104-112.

[6] 倪祥龙,石长安,麻曰亮,等. 基于 Bi-LSTM 的电子装备故障预测方法研究[J/OL]//航空兵器:1-9. [2022-05-19].

[7] SANGHYUN WOO, JONGCHAN PARK, JOON-YOUNG LEE, et al. CBAM: Convolutional Block Attention Module[EB/OL]. <https://doi.org/10.48550/arXiv.1807.06521>,2018-07-17.

Attention Based Mechanism and Multi-sensor Information Driven Fault Prediction System for Hydro-generating Units

TAN Gang¹, DU Lei-hao¹, HU Bian², HE Zhi-cheng¹

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082, China; 2. Hunan Wuling Power Technology Co., Ltd., Changsha 410004, China)

Abstract: To meet the fault prediction needs of hydro-generator units in the context of big data, combining the characteristics of the attention mechanism with good feature extraction ability and the advantages of model robustness for multi-sensor information driving, this paper proposed a fault prediction system of hydro-generating units based on the attention mechanism and multi-sensor information driving. The system was applied to on-line monitoring of unit # 8 in August for a hydropower station in Hunan Province. The actual operation results show that the system can effectively predict the vibration trend of the hydro-generator set and realize the intelligent prediction of the hydro-generator.

Key words: hydro-generators; deep learning; multi-sensor drive; attention mechanism; fault prediction