

基于 DBN 的风电机组变桨系统可靠性动态评估

冯红岩¹, 朱海娜¹, 邱美艳¹, 冯玉龙²

(1.天津中德应用技术大学, 天津 300350; 2.天津瑞源电气有限公司, 天津 300308)

摘要: 为了对风电机组变桨系统的潜在风险进行可靠的动态预测, 针对变桨系统部件种类多、系统复杂、故障特征提取困难的问题, 文章首先对变桨系统故障点和故障传递过程进行归纳分析, 建立故障树; 然后将其转化为融合 Leaky Noisy-Or 节点的动态贝叶斯网络(DBN), 保证了模型精度并具备了动态预测能力; 最后采用 5 折交叉验证的方式对模型进行寻优并验证。测试结果表明, 该方法在对变桨系统进行风险预测、故障致因分析、风险动态演化过程分析方面准确率较高, 可指导变桨系统进行预防性维护, 在保证风电机组整体安全方面具有工程应用价值。

关键词: 变桨系统; 动态贝叶斯网络; 交叉验证; 可靠性评估

中图分类号: TK81 **文献标志码:** A **文章编号:** 1671-5292(2024)04-0486-07

0 引言

风力发电作为一种技术成熟、度电成本非常有竞争力的新能源发电形式, 是实现我国“双碳”战略目标的重要手段。目前, 风电机组的单台功率不断加大, 成本也随之增加, 机组可靠性的提升也变得越来越重要。数据调查结果显示, 风电机组变桨系统的故障率仅次于变频器, 在所有部件中居第二位, 同时变桨系统又是保证风电机组安全的最重要部件。任何工况下, 变桨系统拒动或误动均有导致风电机组飞车、倒塔的风险。因此, 对其潜在风险进行预测分析, 指导机组进行预防性维护, 具有非常重要的意义。

变桨系统的故障预测受到了业内专家和学者的广泛关注。目前, 大多数研究方法均是基于风电场数据采集与监控系统(SCADA)的数据开展故障预测与分析。文献[1]采用熵优化邻域粗糙集模型, 完成不同工况下电动变桨系统特征参量集的实时提取。文献[2]采用最小角回归方法对特征向量进行选择, 针对被选出的特征向量用隐马尔可夫模型建立故障模型, 对故障特征进行提取, 然后再进行故障识别与预测。文献[3]提出了改进的 Relief 算法, 该改进的 Relief 算法鲁棒性较高, 能够降低特征冗余度, 提升故障诊断的准确性与效率。在实际工程中, SCADA 系统对风电机组数据的最低采集周期是秒级, 秒级的数据对变桨系统

通信中断、超级电容异常、刹车断线等故障特征的捕捉是比较困难的。因此, 上述算法在实际系统中的应用还有一定局限性。

贝叶斯网络(BN)对数据的时间分辨率要求相对较低, 是目前不确定知识表达和推理领域最有效的理论模型之一, 可用于结构复杂、内部耦合性强的系统, 其泛在性已经得到了验证^[4]。程江洲^[5]建立了风电机组的 BN 评估模型, 该模型基于质量管理的角度展开, 但没有对风电机组的故障进行具体分析。符杨^[6]针对风电机组采集数据的“多元异质”性对 BN 的应用进行了改进, 研究聚焦于对齿轮箱故障的分析, 说明了分析方法的有效性。考虑到风电机组部件的巨大差异, 该分析方法是否适用于其他部件仍有待验证。

本文聚焦于风电机组的变桨系统, 首先建立了变桨系统故障树, 以直观、清晰地呈现故障发展的过程; 然后建立动态贝叶斯网络(DBN)模型, 使模型具备动态风险预测能力, 引入 Leaky Noisy-Or 节点, 采用 5 折交叉验证的方式提高模型精度; 最后通过测试, 验证了模型的有效性。

1 变桨系统的构成和故障分析

1.1 变桨系统的构成

风电机组变桨系统主要由变桨轴承、减速箱、变桨电机、变频驱动器、后备电源(超级电容)、控制部分和传感器构成。变桨系统工作原理见图 1。

收稿日期: 2022-11-10。

基金项目: 天津市科技计划项目技术创新引导专项优秀特派员项目(20YDTPJC01850)。

作者简介: 冯红岩(1976-), 女, 硕士, 高级工程师, 研究方向为风力发电机组控制与故障诊断。E-mail: fhywww555@sina.com




图 1 变桨系统的构成和原理图

Fig.1 Composition and schematic diagram of pitch system

由图 1 可以看出,变桨系统结构复杂,包含部件种类繁多,系统运行中产生的变量涉及变桨电机的电压和电流、绕组温度、直流母线的电压和电流、后备电源的电压和电流、输入电源的电压和电流、两个编码器反馈的变桨速度和桨角等。在分析变桨系统的运行状态时,还需结合机组的叶轮转速、功率、风速、环境温度等信息。

1.2 变桨系统的故障分析

分析数据来自于 2015 年开始运行,具有 107 台 2 MW 风电机组的某风场,风电机组变桨系统配置相同。对变桨系统故障进行统计,得到的统计结果如表 1 所示。

表 1 某风场变桨系统故障分布

Table 1 Fault distribution of pitch system in a wind farm

故障名称	出现概率/%
变桨控制	40
变桨角度	29
后备电源	17
变桨电机	7
变桨通信	6
变桨驱动	1

由表 1 可以看出,变桨控制、变桨角度故障的占比达到了总故障数的 69%,是影响机组正常运行的主要因素,这两类故障从根本上均可以归为变桨控制系统故障。不同的故障对整个系统的安全影响是不同的,比如,通信故障一旦发生,将使整台风电机组面临重大风险,而两叶片桨角差异超限较小给系统带来的影响不是很大。对于模拟量超限引起的故障,超限程度不同,对系统的影响

程度也不同,因此,二值模型显然不能满足分析的需要。为了保证精度,需要对部分故障节点建立多态模型进行分析。

2 研究思路与方法

通过变桨系统运行的历史数据分析,筛选出常见故障,统计其致因,建立变桨系统的故障树。故障树的不足是不能定量呈现风险因素传播链上下级间不确定的因果关系。而 DBN 可以弥补故障树的这一不足,还能从概率的角度对风险进行向前预测和向后诊断,同时具有描述事件多态性和故障逻辑关系非确定性的能力,因此,本文基于故障树建立系统的 DBN 模型。

2.1 DBN 的基本理论

DBN 由节点、弧和条件概率表(CPT)组成。节点表示随机变量,弧表示节点之间的条件依赖,CPT 表示从子节点到父节点,以及节点从上一个时间片到下一个时间片的转换逻辑^[7]。

DBN 的所谓动态,动的只是连接概率,网络结构是固定的。构建 DBN 模型分为两步,一是先建立静态贝叶斯网络 B_0 ,即初始时刻 BN 的结构和概率分布,二是建立包含时间片的状态转移网络 $B \rightarrow$ 。相邻时间片节点变量之间的条件概率分布为

$$P(X_t | X_{t-1}) = \prod_{i=1}^N P[X_{t,i} | pa(X_{t,i})] \quad (1)$$

式中: X_t 为 t 时刻的变量; X_{t-1} 为 $t-1$ 时刻的变量; $X_{t,i}$ 为时间片 t 中的第 i 个节点; $pa(X_{t,i})$ 为 $X_{t,i}$ 的父节点集,存在于同一个时间片内或者上一个时间片中。

跨越多个时间片的概率分布可表示为^[8]

$$P(X_{1:T}) = \prod_{t=1}^T \prod_{i=1}^N P[X_{t,i} | pa(X_{t,i})] \quad (2)$$

式中: $X_{1:T} = \{X_1, X_2, \dots, X_N\}$ 。

2.2 Leaky Noisy-Or gate 数学模型

建立的 DBN 不一定能将实际系统中所有的故障点都考虑在内,即当所列出的故障原因均未发生的情况下,变桨系统也可能出现故障,因此引入遗漏概率。将节点扩展为 Leaky Noisy-Or 节点,当所有的父节点都取假时,会有遗漏节点 X_L 存在,使子节点仍有可能取真。用 Leaky Noisy-Or 节点建立模型,更符合变桨系统的实际情况,使模型的精确度更高。

假设子节点 Y 只有两个父节点 X_L 和 X_{com} , X_{com} 是除去 X_L 外其他因素的总和。当其他因素均为假, 只有遗漏节点 X_L 导致 Y 发生的概率可表示为

$$P_i = P(Y | X_L, \bar{X}_{com}) = P(Y | \bar{X}_{com}) \quad (3)$$

当遗漏节点为假, 其他因素 X_{com} 导致 Y 发生的概率可表示为

$$P_{com} = P(Y | X_{com}, \bar{X}_L) = P(Y | \bar{X}_L) \quad (4)$$

根据 Noisy-Or gate 模型, 则有:

$$P(Y | X_L) = P_i + P_{com} - P_i P_{com} \quad (5)$$

由以上各式推导出 Y 与遗漏节点的连接概率为

$$P_i = \frac{P(Y | X_L) - P(Y | \bar{X}_L)}{1 - P(Y | \bar{X}_L)} \quad (6)$$

2.3 模型训练

根据实际情况, 将 DBN 中部分节点的风险状态分为 3 个等级, 即正常、警告、故障, 分别用 0, 1, 2 标识。模型训练主要指网络的先验概率、条件概率、后验概率的学习, 以及状态转移概率的确定。

2.3.1 模型的参数学习

BN 的最典型应用即由先验概率和相关条件来推导节点后验概率。

$$P(X_i | Y) = \frac{P(Y | X_i) P(X_i)}{P(Y)} = \frac{P(Y | X_i) P(X_i)}{\sum_{i=1}^n P(X_i) P(Y | X_i)} \quad (7)$$

式中: $P(X_i)$, $P(Y)$ 分别为 X_i , Y 的先验概率; $P(X_i | Y)$ 为后验概率, 即在 Y 发生的情况下, X_i 发生的概率; $P(Y | X_i)$ 为条件概率, 即 X_i 发生的条件下, Y 发生的概率。

$P(Y)$ 直接由运行数据统计获得。 X_i 是 Y 的致

因, $P(X_i)$ 由对故障进行分析处理后记录的故障原因数据获得, 缺失数据通常可以假设其服从指数分布^[9]。

$$P(X_i^k) = 1 - e^{-\lambda_k t} \quad k=1, 2 \quad (8)$$

式中: λ_k 为节点 X_i^k 的故障率, 由设计、试验或同型号产品的统计数据得到。

确定各个节点的概率后, 即可进行条件概率和后验概率的计算。因为在研究中只统计了高频故障的数据, 所以在进行条件概率计算时, 引入 Leaky Noisy-Or gate 模型。

2.3.2 监测信息更新与状态转移概率

监测信息更新是指随着更新时刻 T_k 的推移, 不断获取新的状态监测信息时, 各个节点的状态数据随之更新的过程。当系统在运行中有新的故障产生时, 更新所有节点的数据, 并对整个模型进行更新运算。

状态转移概率是指多状态节点在 T_{k+1} 时刻, 相对 T_k 时刻, 节点在不同状态之间转移的概率。

$$P(E_{T_{k+1}}=m | E_T=n) = \begin{cases} \varepsilon & m=n \\ \frac{1-\varepsilon}{D-1} & m \neq n \end{cases} \quad (9)$$

式中: m, n 分别为 T_{k+1} 和 T_k 时刻节点的状态; ε 为节点状态不变的概率, 根据式(1)或式(2)求出; D 为状态总个数, 本文多数节点 $D=3$ 。

3 案例分析

以某风场 107 台 2 MW 风电机组的变桨系统为例, 进行建模和分析。

3.1 变桨系统故障树的构建

首先, 根据图 1 所示的变桨系统的构成和工作原理, 确定变桨系统故障为故障树顶事件, 用 T 表示(图 2)。然后, 按照驱动器、电机、后备电源、控制和通信 5 部分分类, 分别对应 M1, M2, ...,

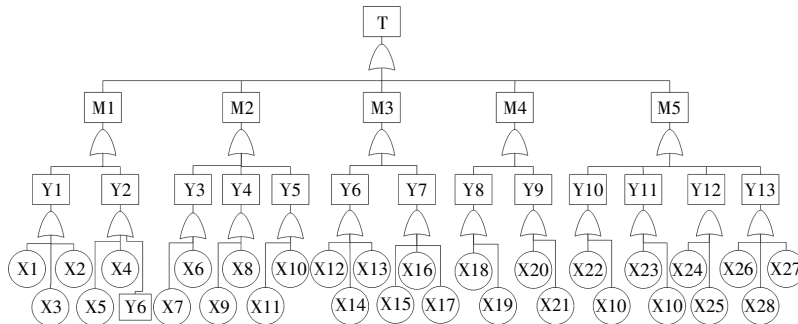


图 2 变桨系统故障树

Fig.2 Fault tree of pitch system

M5。对每一个构成部分的常见故障进行深入分析和全面梳理,确定高频故障事件 13 个,分别对应 Y1, Y2, …, Y13, 变桨系统在运行中可以对该层次事件直接监测。最后,对每一个事件 Y 进行致因分析,确定故障病症,即根节点,确定根节点 28 个,分别对应 X1, X2, …, X28。将处于同一层次的

事件,据实际逻辑关系用“与”门或“或”门连接,并用有向箭头与相邻层次相连,即得到整个变桨系统的故障树模型。其中“M5 变桨控制故障”除了包含变桨控制系统本身的故障外,还包括变桨角度故障和传感器故障。M2 后备电源默认为超级电容。事件的具体说明见表 2。

表 2 变桨系统故障事件及概率
Table 2 Fault event and probability of pitch systems

节点	事件	$P(1)/10^{-3}$	$P(2)/10^{-3}$	节点	事件	$P(1)/10^{-3}$	$P(2)/10^{-3}$
T	变桨系统故障	32.81	21.7	X12	充电超时	1.2	0.86
M1	驱动器故障	0.24	0.33	X13	充电器损坏	0.39	0.75
M2	变桨电机故障	2.34	1.66	X14	充电器通信故障	—	0.93
M3	后备电源故障	5.88	2.69	X15	电池柜温控系统故障	0.08	0.02
M4	通信故障	—	2.34	X16	串并联连接松动	—	0.04
M5	变桨控制故障	24.35	14.2	X17	电容单体性能降低	1.2	0
Y1	驱动器过流或过温	0.18	0.42	Y8	外部通信故障	—	3.9
Y2	直流母线电压异常	0.56	0.62	Y9	内部通信故障	—	0.12
X1	电流检测回路故障	—	0.32	X18	通信线虚接或断开	—	1.83
X2	内部短路	—	0.01	X19	滑环接触不稳定	—	1.65
X3	散热系统故障	—	0.83	X20	航空插头松动	—	0.13
X4	400 V 电源故障	0.11	0.9	X21	通信控制板损坏	—	0.11
X5	加减速时间短	0.06	0	Y10	回桨超时	12.4	10.11
Y3	绕组温度超限	0.33	0.97	Y11	桨角偏差超限	7.3	3.18
Y4	刹车失败	1.34	0.86	Y12	主副编码器偏差过大	2.9	0.02
Y5	电机过流	1.2	0.11	Y13	变桨安全链断开	0.52	0.427
X6	匝间短路	—	0.02	X22	电机驱动功率偏低	2.23	2.1
X7	散热或测温故障	—	0.11	X23	传感器零位待校准	2.9	2.3
X8	刹车断线或虚接	—	0.78	X24	主旋编损坏或松动	2.2	1.9
X9	电磁刹车故障	—	0.01	X25	副旋编损坏或松动	2.1	0.02
X10	变桨机械传动卡涩	10.6	8.2	X26	95°限位开关被撞开	—	4.88
X11	输出短路	—	0.01	X27	LVRT 故障	—	0.13
Y6	超容电压超限	1.12	1.62	X28	变桨控制器故障	—	0.9
Y7	超容温度超限	0.073	0.042	X29	高于额定功率运行	—	23

注:—代表该节点没有此状态; $P(1)$ 和 $P(2)$ 表示对应节点处于 1 和 2 状态的概率,其值由 107 台风电机组在 20200101–20220801 运行数据统计得到。

3.2 DBN 模型建立

将故障树模型转化为 BN 模型,对模型进行定量分析。因为变桨系统故障树建立时只考虑了故障的传递关系,风电机组安装地的天气条件也是风险因素。因此,增加根节点“X29 高于额定功率运行”与 X5, X6 共同影响 Y3。根据 1.2 节的分析,由故障树向 BN 转化时,需要对 BN 中节点建立多态模型。如果节点只有两种状态,比如“M4 通信故障”节点,则将其发生后的状态归入“故障”,取消“警告”状态。

本文在 GeNie4.0 中建立变桨系统的 DBN 模

型,选择受时间因素影响较大的“Y3 电机绕组温度”、“Y7 超容温度”、“Y11 桨角偏差超限”3 个节点,建立其在前后两个时间片的转移概率。建模时, T 和 X_i 选为一般节点 (general), 其他子节点选为 “NoisyMax” 节点, 加入遗漏节点的影响。在综合先验信息和数据信息的前提下,生成整体数据文件,对模型进行训练。训练完毕后,统计遗漏概率,如果某节点的遗漏概率超过 10%,则对模型结构进行更新;然后重新训练,直至每个节点的遗漏概率均低于 10%。最终确立的 DBN 模型如图 3 所示。

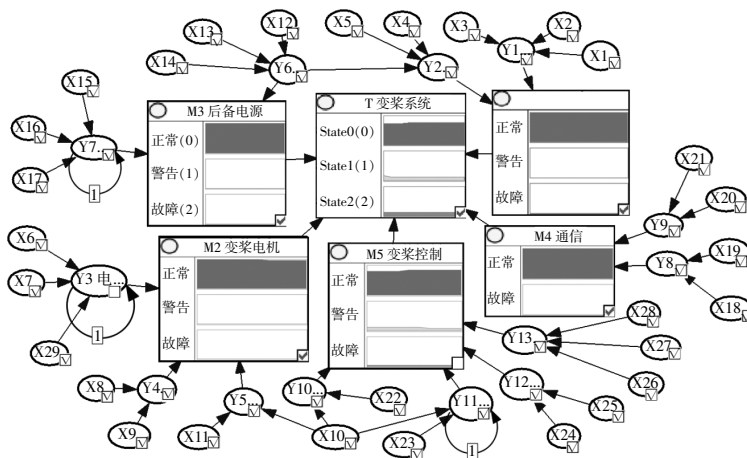


图3 变桨系统的动态贝叶斯网络模型

Fig.3 Dynamic Bayesian network model of pitch system

3.3 模型的寻优与可靠性验证

从 107 台机组中随机抽取 105 台机组的数据,采用 5 折交叉验证的方式对模型进行可靠性验证。验证参数选择所有 X 和 Y 节点。将 105 组数据进行 5 折交叉验证后,返回 5 次验证的平均得分,以此为指标进行最大值寻优。寻优方式是每轮验证完后,将整体数据的最后一组数据提到最前面进行数据更新,以此改变数据分组中的元素,经过 21 个循环即可遍历所有数据分类方式。经 21 次验证后,得到寻优最大值为 0.904,对应的该轮 5 次验证的得分如表 3 所示。取与寻优最大值最接近的第 4 次验证用的训练数据进行最终模型的训练,以此保证最终模型不仅具有较高的可靠性,而且具有较强的泛化能力。

表 3 模型交叉验证寻优的结果

Table 3 Results of model cross validation and optimization

验证次数	得分
1	0.892
2	0.934
3	0.867
4	0.902
5	0.926
平均值	0.904

4 变桨系统 DBN 的应用测试

应用剩余两台变桨系统同时期的故障数据作为模型的测试数据,从以下 3 方面测试模型的应用效果。

4.1 故障致因分析

在模型中将关注的子节点的故障状态设为 1,模型可自动对各父节点进行致因概率计算和重

要度分析。通过对比模型的 CPT 和实际两台机组的故障统计数据,计算得到模型对所有 Y 节点的重要度分析结果准确度均值为 88.7%。这表明,模型可用于对故障致因进行初步判断,并辅助进行故障分析。

4.2 可靠性预测

利用一台机组同期测试数据,输入到已经训练好的模型中,并将时间片数量设定为 10 进行运算,可得到变桨系统每个节点可靠度随时间的变化曲线。变桨电机、超级电容和变桨控制系统的可靠度变化曲线如图 4 所示。利用该分析结果,可以预测部件性能在没有人干预情况下的衰减速度,有助于进行预防性检修或及时更换部件。




图 4 电机和超级电容的可靠度预测曲线

Fig.4 Reliability prediction curve of motor and super capacitor

4.3 动态节点的风险演化过程分析

基于所建模型对动态节点的风险演化过程进行预测。以超容温度超限为例,将超级电容温度超限 1(警告)在起始时刻设为证据节点,模型可以

计算出风险演化过程(图 5)。




图 5 超级电容温度超限风险演化过程

Fig.5 Evolution process of super capacitor temperature overrun risk

由图 5 可知,温度超限 2(故障)发生的概率在第三个时间片内达到峰值。运维人员可以在该数据帮助下,判断变桨系统对风险的承受能力,以决定在超级电容温度达到超限 1 时,采取何种处理措施。

在数据分析过程中发现,如果忽略变桨系统的大部件更换或检修,将前后数据混一起,将导致可靠性预测和动态节点的风险演化过程结果不准确,这是在应用中需要注意的。

5 结束语

本文首先建立变桨系统故障树,整理出变桨系统故障发展的脉络,在此基础上,建立融合 Leaky Noisy-Or 节点的变桨系统 DBN 多态模型,保证了模型的精度,并具备了动态分析能力。设计了一种基于 5 折交叉验证方式的模型寻优验证方法,以提高模型的可靠性和泛化能力。最后利用现场数据对模型进行测试。从测试结果可以看出,所

建模型的准确度较高,可以辅助进行变桨系统故障致因分析,并能进行部件可靠性动态预测和节点的风险演化过程预测。

参考文献:

- [1] 王爽心,郭婷婷,李蒙.风电机组变工况变桨系统异常状态在线识别[J].中国电机工程学报,2019,39(17):5144-5152,5295.
- [2] 孙群丽,周瑛,刘长良.基于 LARS 特征选择的风电机组故障诊断的研究 [J]. 可再生能源,2020,38(10):1349-1354.
- [3] 胡鑫.风电机组变桨系统故障诊断方法研究[D].吉林:东北电力大学,2021.
- [4] 魏乐,胡晓东,尹诗.基于优化 XGBoost 的风电机组发电机前轴承故障预警 [J]. 系统仿真学报,2021,33(10):2335-2343.
- [5] 程江洲,冯馨以,王灿.基于贝叶斯网络的风力发电系统动态风险评估[J].计算机仿真,2023,40(10):108-112.
- [6] 符杨,苗育植,黄玲玲,等.基于改进贝叶斯网络的风电机组动态可靠性评估[J].电力自动化设备,2022,42(11):32-39.
- [7] George P G, Renjith V R. Evolution of safety and security risk assessment methodologies to use of Bayesian networks in process industries [J]. Process Safety and Environmental Protection, 2021, 149: 758 - 775.
- [8] Chang Y J, Wu X F, Zhang C S, et al. Dynamic Bayesian Networks based approach for risk analysis of subsea wellhead fatigue failure during service life [J]. Reliability Engineering and System Safety, 2019, 188: 454-462.
- [9] 白旭,汤荣铿,罗小芳,等.基于故障树分析和贝叶斯网络方法的半潜式钻井平台系统多状态可靠性分析 [J]. 中国造船, 2020, 61(2): 220-228.

Dynamic reliability evaluation of wind turbine pitch system based on DBN

Feng Hongyan¹, Zhu Haina¹, Qiu Meiyan¹, Feng Yulong²

(1.Tianjin Sino-German University of Applied Sciences, Tianjin 300350, China; 2.Tianjin Resource Electric Co., Ltd., Tianjin 300308, China)

Abstract: In order to make reliable dynamic prediction of the potential risk of pitch system, aiming at the problems of multiple components, complex system and difficult fault feature extraction of pitch system, the fault tree is established through the induction and analysis of its fault point and fault transmission process, and then it is transformed into a dynamic Bayesian network (DBN) integrating Leaky Noisy-or nodes, which ensures the accuracy of the model and has the dynamic prediction ability. The model is optimized and verified by using a 5-fold cross-validation method. The test results show that this method has high accuracy in risk prediction, fault cause analysis and risk dynamic evolution process analysis of pitch system, and has engineering application value in guiding the preventive maintenance of pitch system and ensuring the overall safety of wind turbine.

Keywords: pitch system; dynamic Bayesian network; cross validation; reliability evaluation