

基于状态自适应评估的海上风电机组预防性维护策略

符 杨¹, 黄路遥¹, 刘璐洁¹, 魏书荣¹, 任浩瀚², 王 毅², 唐庚培²

(1. 上海电力大学 电气工程学院, 上海 200090; 2. 上海绿色环保能源有限公司, 上海 200433)

摘要:针对海上风电机组对故障特征的增量式学习及主动维护的问题,提出了一种基于状态自适应评估的海上风电机组预防性维护策略。首先,采用非正态总体假设检验量化机组实时状态与典型状态的信息差异,通过增量字典学习捕捉机组典型状态特征,基于支持向量机构建了机组状态自适应评估模型。然后,结合部件有效役龄,以机组状态概率向量为决策依据、单次维护费用最小为目标,优化部件维护策略。同时计入部件成组时由于提前或延迟维护的损失,以维护总费用最小为目标、日维护时长为约束,建立了基于状态自适应评估的海上风电机组预防性维护模型。最后,以某海上风电机组为例,验证了所提维护策略的有效性,分析了维护次数、可及性对维护策略的影响。

关键词:海上风电机组;状态空间划分;增量字典学习;状态自适应评估;预防性维护

中图分类号:TM 614;TK 83

文献标志码:A

DOI:10.16081/j.epae.202110009

0 引言

在我国2030年前实现碳达峰、2060年前实现碳中和的目标愿景下^[1],近年来海上风电作为新能源领域重要组成部分保持较快的增长速度。截至2020年,全球新增装机容量6 GW,其中我国新增装机容量超过3 GW^[2]。受雷击、盐雾、风载荷等环境因素的影响,海上风电机组故障率高、类型成因多样且维护可及性较差,运维费用占其度电费用的1/4以上^[3],运行维护费用居高不下。在平价压力下,如何通过优化维护策略来降低维护费用已成为海上风电行业实现持续发展的重要方向,也是加速推进碳达峰、碳中和战略的重要支撑。

目前海上风电机组普遍采用事后维护和预防性维护相结合的维护策略^[4]。事后维护是指机组发生故障后所进行的非计划性被动维护,由于缺少必要的维护准备,机组停机时间较长。预防性维护又分为定期维护和状态维护。定期维护是结合机组历史故障数据,基于时间或寿命周期的维护,但由于机组各部件的实际退化程度不同,到期就修的定期维护方式易造成“维护不足”或“维护过剩”问题。随着机组状态监测技术的发展,多源异质的监测数据为状态的精准估计提供了良好的基础,基于机组状态的维护策略成为近年来研究的热点^[5]。目前研究主要围绕以下2个方面开展。一是基于机组当前状况评

估制定维护策略^[6],在根据评估机组当前实际状态的基础上,将其与预设故障阈值比较来判断是否进行维护。文献[7]在对海上风电机组部件进行统计分析的基础上,指出了机组状态评估中的关键部件,并对现有状态评估方法进行梳理。文献[8]结合机组主轴温度残差信息统计结果,同时引入残差均值作为状态监测量,实现对主轴状态的实时监测。文献[9]根据风轮状态的识别结果,以劣化状态为决策依据,并以风轮维护费用最小为目标制定其维护策略。文献[10]提出了一种描述部件实时运行状态的状态指示器,通过比较其与状态维修阈值函数之间的大小来确定部件的维护策略。二是基于机组未来状况预测制定维护方案,研究方法通常分为基于数学模型(如比例风险模型、滤波模型等)预测和基于数据驱动预测。文献[11]基于机组轴系裂纹损伤机理,构建了轴系退化-扭转耦合模型,同时引入风速对轴系退化过程的影响,实现对轴系剩余寿命的预测。文献[12]在利用神经网络预测状态后,基于各部件故障概率值,以单位时间维护费用的期望值最小为目标优化维护策略。文献[13]基于最大似然估计建立退化预测模型,并提出一种用于确定部件最优更换方案的单调控制极限解策略。

上述状态维护中存在以下2个方面问题。一方面,相比于陆上风电,海上风电机组运行环境复杂多变,导致机组运行监测数据波动剧烈,不确定运行环境下的时变监测数据增加了准确评估机组状态的难度。此外,海上风电机组故障类型更为复杂多样,机组状态特征的提取是增量式的,需要在历史状态特征的基础上不断从新样本中学习新知识,对机组状态特征的增量式学习还有待建立更系统的方法和模型。另一方面,当前研究多以优化短期单次维护策略为主,但机组在采用不同维护方式后其状态也随之变

收稿日期:2021-03-05;修回日期:2021-08-10

基金项目:上海绿色能源并网工程技术研究中心项目(13DZ2251900);上海市科技创新行动计划研究项目(18DZ1202400)

Project supported by Shanghai Engineering Research Centre of Green Energy Grid-Connected Technology(13DZ2251900) and the Project of Shanghai Science and Technology Innovation Action Plan(18DZ1202400)

化^[14]。在机组状态与维护策略间的动态不确定相互影响下,兼顾短期局部与全寿命周期全局的最优维护决策仍存在困难。因此,如何建立具备自适应学习能力的状态评估模型对指导状态维护意义重大。

本文针对机组状态评估中对新问题学习能力不足的问题,利用非正态总体假设检验法判定表示新状态的状态数据,并基于增量字典学习实时更新状态评估知识库。由于在采用单个样本测试时,状态评估模型的输出结果固定,可能与机组实际状态存在误差,但使用机组相同状态下的多个样本数据进行状态评估后,其结果具有统计特性,评估结果以概率向量形式输出。因此,在原有的自适应评估模型的基础上,以结合支持向量机(SVM)输出的机组各状态的概率向量为决策依据,制定各部件的预防性维护策略。然后,依据在不同窗口期的成组维护费用差异情况,得出最优的预防性维护策略。最后,以某海上风电机组为例,仿真验证所提模型的有效性,并分析了维护次数和可及性对维护策略的影响。

1 基于状态自适应评估的海上风电机组预防性维护策略思路框架

1.1 模型假设

模型假设如下:①依据机组性能衰退趋势,将机组状态空间划分为机组正常、轻度异常、中度异常、重度异常、故障5个状态;②部件预防性维护间隔为等周期,且小修和大修对应的有效役龄为常数;③不考虑维护资源及部件故障相关性的影响。

1.2 思路框架

基于状态自适应评估的海上风电机组预防性维护策略分为状态自适应评估和预防性维护2个阶段,具体如下。

1)状态自适应评估阶段。结合机组数据采集与监视控制(SCADA)系统采集的状态数据和维护日志,将相邻2次消缺结束时刻间的状态数据聚类,完成机组状态空间划分。采用增量字典学习法,对历史状态数据进行学习,获得初始字典及初始稀疏矩阵。通过假设检验对比机组实时状态与历史状态,若假设检验结果为真,则表示该部件出现新故障诱因,在原有字典的基础上进行增量字典学习,获取增量字典及增量稀疏矩阵。采用SVM,将增量字典和实时状态数据作为输入,在得到实时数据映射到线性空间上的系数向量后,评估该部件处于各状态的概率,以概率最大值时的状态作为评估结果。

2)预防性维护阶段。结合部件当前状态概率向量,使用迭代法优化部件下次预防性维护间隔及维护方式,并依据维护后的状态数据按上述方法逐次优化维护策略,形成各部件长期维护决策。在此基础上,以天为单位,滚动监测时间窗,再计入部件提前维护或延迟维护产生的惩罚费用,以机组长期维

护费用最小为目标,优化得到短期内成组维护的部件集及其维护方式。

2 基于增量字典学习和SVM的海上风电机组状态自适应评估

在划分机组状态空间的基础上,采用非正态总体假设检验识别机组新故障数据,为了使评估模型自适应更新新知识,提出了基于增量字典学习和SVM的海上风电机组状态自适应评估模型。

2.1 海上风电机组状态空间划分

机组故障多样,当机组逐级劣化甚至发生故障时,相较于正常状态,状态监测测量的数值将出现增减。因此,通过选择表征机组正常状态的SCADA系统数据样本,根据状态值量化其他状态的故障程度,实现海上风电机组状态空间划分。

2.1.1 基于平衡迭代规约聚类法的机组正常状态聚类中心确定

机组由于长期处于高湿、高盐的工作环境,并且在长期风载荷耦合作用下,其各个部件的风险和疲劳程度不断累积,机组部件状态演变将经历正常—异常—故障的过程。考虑到SCADA系统所采集数据的非线性程度强,且采样过程严格遵循时序性等特点,本文采用平衡迭代规约聚类法(BIRCH),借助其对大量高维非线性数据的聚类质量高、节约内存、聚类时间短等方面的优势^[15],通过按数据排列的先后次序,构建聚类特征树存储聚类簇的特征,在增添机组新状态数据的同时实现对机组状态的无监督聚类。将正常状态簇中心所对应的状态数据作为机组正常信息的“代表”,当机组状态变化时,表征机组状态的状态量的值出现不同程度的增减。因此,确定机组正常状态簇中心并以其状态数据作为基准,是划分状态空间的首要步骤。

定义机组相邻2次消缺结束时刻间的时间段为单位监测周期,在第 v 个单位监测周期内,SCADA系统将采集到的 N 个 M 维机组状态数据样本按时序排列构成待聚类矩阵, $\mathbf{x}_f$ 为第 f 个状态数据样本, x_{fo} 为 $\mathbf{x}_f$ 中的第 o 个状态参量值。每个聚类簇由聚类特征 C_f (包括状态数据样本数 N 、样本数据线性和向量、各样本点数据平方和)表征,记聚类簇 p 和聚类簇 q 的第 f 个状态数据样本分别为 $\mathbf{x}'_f$ 和 $\mathbf{x}''_f$,且聚类簇 p 和聚类簇 q 的状态数据样本数量分别为 N_p 和 N_q ,由此推导出的簇中心 $\bar{\mathbf{x}}$ 、簇半径 R 及聚类簇 p 与聚类簇 q 之间间距 d 分别如式(1)—(3)所示。

$$\bar{\mathbf{x}} = \left(\sum_{f=1}^N \mathbf{x}_f^T \right) / N \quad (1)$$

$$R = \sqrt{\left[\sum_{f=1}^N \sum_{o=1}^M (x_{fo} - \bar{x}_o)^2 \right] / N} \quad (2)$$

$$d = \sqrt{\frac{\sum_{f=1}^N \mathbf{x}'_f \mathbf{x}'_f{}^T}{N_p} + \frac{\sum_{f=1}^N \mathbf{x}''_f \mathbf{x}''_f{}^T}{N_q} - \frac{2 \sum_{f=1}^N \mathbf{x}'_f \sum_{f=1}^N \mathbf{x}''_f{}^T}{N_p N_q}} \quad (3)$$

式中: $\bar{x}_o$ 为聚类中心的第 o 个状态参量值。

BIRCH 首先设定叶平衡因子 τ 和枝平衡因子 φ 的数值,对读入的首个机组状态数据样本 $\mathbf{x}_1$ 计算 C_{F1} ,同时将其放入根节点中,当读入下一个机组状态数据样本 $\mathbf{x}_2$ 计算 C_{F2} 后,比较两簇间距与 $\mathbf{x}_1$ 簇半径,若 $d < R$,则将 2 个样本归为一类,并将 C_F 合并;反之,则建立新的枝节点。当叶节点数超过叶平衡因子 τ 时,将枝节点一分为二,同理,当枝节点数超过枝平衡因子 φ 时,将根节点一分为二。最后,以聚类数量为约束,将距离相近的数据簇合并。聚类结果及正常状态簇中心见附录 A 图 A1。

2.1.2 基于欧氏距离的机组状态空间划分

机组部件劣化过程中,机组状态量(如温度、电流、电压等)也随之变化。欧氏距离作为量化状态量变化幅度的一种参数,能更好地将机组劣化阶段细分。为了获取各状态空间的状态数据,选取正常状态下聚类中心样本值作为基准值,记 f' 为单位监测周期内正常状态聚类中心样本位次,通过计算单位监测周期内第 o 个状态参量值 x_{fo} 与正常状态下第 o 个状态参量值 $x_{f'o}$ 间的欧氏距离标幺值 d' ,实现对机组状态空间划分。在参考欧氏距离计算公式^[16]的基础上,欧氏距离标幺值 d' 的计算公式如式(4)所示。

$$d' = \sqrt{\sum_{o=1}^M (x_{fo} - x_{f'o})^2} / x_{f'o} \quad (4)$$

欧氏距离标幺值 d' 越大,表示该样本的状态参量值与机组正常状态下的样本参量值差别越大,机组运行累积的风险越高。因此,单位监测周期内的状态数据划分正常、轻度异常、中度异常、重度异常和故障,划分结果如图 1 所示。




图1 基于欧氏距离的机组劣化过程再划分
Fig.1 Subdivision of degradation process of units based on Euclidean distance

2.2 海上风电机组状态增量集判定

对实时数据中蕴含的新故障类型判别是增量式学习的基础。部件在不同故障诱因下,状态数据集间存在的相对信息损失将导致其幅值谱概率密度函数不同,因此采用非正态总体假设检验^[17]。

设 Y' 和 Y'' 分别为历史状态数据集和实时状态数据集, Y' 的均值为 u_0 , Y'' 由 l 个 SCADA 系统机组状态数据样本组成,其均值和方差分别为 E 和 σ^2 。在显著性水平 α 下,检验假设 $H_0: E = u_0, H_1: E \neq u_0$ 。由于总体方差已知,依据中心极限定理,在原假设 H_0 成立的条件下,检验统计量服从标准正态分布。统计量 r 的表达式如式(5)所示,对 r 进行 U 检验,当 H_0 为真时,统计量 r 的拒绝域如式(6)所示。

$$r = \frac{|E - u_0|}{\sigma \sqrt{l}} \quad (5)$$

$$\{|r| > u_{1-\alpha/2}\} \quad (6)$$

若满足式(6),则拒绝 H_0 ,此时,表示两数据集信息差异较大,实时状态数据集可作为对应状态空间的增量数据集;否则,接受 H_0 ,表示实时数据与历史数据信息差异程度低,即部件的故障诱因已在知识库中,且实时状态数据集不作为增量集。

2.3 基于增量字典学习和 SVM 的海上风电机组状态自适应评估模型

海上风电机组状态自适应评估是制定机组维护策略的前提,分为状态自学习阶段和状态评估阶段。在状态自学习阶段,结合状态监测数据、维护日志等信息,通过增量字典学习实现对新知识的自学习;在状态评估阶段,为了降低硬分类造成的误差,结合训练出的增量字典,以实时状态数据为输入,输出机组处于各状态的概率向量,以概率值最大的状态作为机组状态自适应评估结果。

2.3.1 状态自学习阶段

初始字典学习是进行增量字典学习的必要环节。结合机组维护日志和 SCADA 系统数据,将表征部件首次故障的状态数据记作初始训练集 $Y_{(0)}$,初始字典 $D_{(0)}$ 和稀疏矩阵 $X_{(0)}$ 可由式(7)训练得到。

$$\operatorname{argmin}_{D_{(0)}, X_{(0)}} \left\{ \|Y_{(0)} - D_{(0)} X_{(0)}\|_2^2 + \lambda \|X_{(0)}\|_2 \right\} \quad (7)$$

式中: λ 为平衡参数;函数 $\operatorname{argmin} \{\cdot\}$ 表示使目标函数 $\{\cdot\}$ 取最小值时的变量值。将 $D_{(0)}$ 的 m 个列向量记为字典原子 $\{d_1, d_2, \dots, d_m\}$ 。设某一时间段内,识别出该部件的 U 个互斥故障诱因后,在原有状态空间初始字典的基础上,将表征每个故障诱因的状态数据依次作为增量字典学习的训练集,记 U 个增量字典学习的训练集集合为 $\{Y_{(1)}, \dots, Y_{(j)}, \dots, Y_{(U)}\}$ ($Y_{(j)}$ 为第 j 个增量字典学习的训练集)。在对首个增量字典学习的训练集 $Y_{(1)}$ 自适应特征值提取前,判断 $Y_{(1)}$ 在通过初始字典和稀疏矩阵重构后是否满足误差容许范围要求 ($Y_{(1)} \approx D_{(0)} X_{(0)}$),若满足,则将初始字典 $D_{(0)}$ 作为增量字典 $D_{(1)}$,否则在初始字典中增加 b 个字典原子构成新的增量字典 $D_{(1)}$,后续的增量字典数据构造依此类推。对于第 $j+1$ 个增量字典学习的

训练集 $Y_{(j+1)}$, 其增量字典 $D_{(j+1)}$ 和稀疏矩阵 $X_{(j+1)}$ 可通过式(8)求取^[18]。

$$\operatorname{argmin}_{D_{(j+1)}, X_{(j+1)}} \left\{ \left\| Y_{(j+1)} - D_{(j+1)} X_{(j+1)} \right\|_2^2 + \lambda \left\| X_{(j+1)} \right\|_2 \right\} \quad (8)$$

将机组实时状态数据输入自适应评估模型后, 依据假设检验判别情况, 结合新故障数据对原有状态空间中的字典进行更新, 并采用分段函数 F 表示该过程, 所提模型如式(9)所示。

$$F = \begin{cases} X_{(j+1)} = X_{(j)}, D_{(j+1)} = D_{(j)} & \left| \frac{E - u_0}{\sigma \sqrt{l}} \right| < u_{1-\alpha/2} \\ \operatorname{argmin}_{D_{(j+1)}, X_{(j+1)}} \left\{ \left\| Y_{(j+1)} - D_{(j+1)} X_{(j+1)} \right\|_2^2 + \lambda \left\| X_{(j+1)} \right\|_2 \right\} & \left| \frac{E - u_0}{\sigma \sqrt{l}} \right| \geq u_{1-\alpha/2} \end{cases} \quad (9)$$

式中: $X_{(j)}$ 和 $D_{(j)}$ 分别为 $Y_{(j)}$ 对应的稀疏矩阵和增量字典。式(9)中对应于 α 的 u 值可通过历史数据训练并查找 t 界值表确定。

2.3.2 状态评估阶段

在得到各状态空间增量字典和稀疏矩阵后, 由于实时状态数据是非线性不可分的, 利用 SVM 建立超平面, 并计算实时状态数据所属状态空间概率, 以概率最大值作为机组状态评估的结果, 实现机组状态分类。

由于 SVM 的特征空间要求线性输入, 需要对实时状态数据 y 进行空间变换, 因此通过增量字典可得如式(10)所示映射到线性空间上的系数向量 z 。

$$z = (D_{(j+1)}^T D_{(j+1)} + \partial I)^{-1} D_{(j+1)}^T y \quad (10)$$

式中: ∂ 为状态评估平衡因子; I 为单位矩阵。基于 SVM 的多分类问题的主要任务是寻找多个决策函数, 旨在根据输入信息划分到状态空间中, 状态 i 的决策函数如式(11)所示。

$$f_i(z) = \omega_i^T z + b_i \quad (11)$$

式中: ω_i 为超平面法向量; b_i 为超平面的偏置。结合历史状态数据, 计算实时状态数据所属每个超平面划分空间的概率, 构建 SVM 分类器实时状态数据 y 所属状态 i 的概率 p_i ^[19] 及机组状态评估结果 e 分别如式(12)、(13)所示。

$$p_i = P(y=i|z) = \frac{1}{1 + e^{A_i f_i(z) + B_i}} \quad (12)$$

$$e = \operatorname{argmax} \{ p_i \} \quad (13)$$

式中: A_i 、 B_i 为状态 i 中参数, 由极大似然估计得出; 函数 $\operatorname{argmax} \{ \cdot \}$ 表示使目标函数 $\{ \cdot \}$ 取最大值时的变量值。

3 基于状态自适应评估的海上风电机组预防性维护模型

结合当前时刻部件状态向量, 通过计算小修、大

修次数的期望和有效役龄, 对传统部件预防性维护费用和停机费用进行修正, 以维护总费用最小为目标, 提出了基于状态的部件预防性维护模型, 确定下次(短期)维护时刻及维护方式; 在此基础上, 结合各部件有效役龄确定提前维护或延迟维护产生的变动费用, 以全寿命周期(长期)维护总费用最小为目标, 提出了基于状态自适应评估的海上风电机组预防性维护模型, 通过分析各种成组方案下维护费用, 确定各部件短期成组时刻及待维护部件, 实现了长短期维护策略的配合。

3.1 部件预防性维护模型

制定机组部件预防性维护任务是出海成组维护的基础。设初始预防性维护间隔为 T , 在采取不同的维护方式(不维护、小修、大修、更换)下, 机组部件性能的恢复程度不同。当维护方式为不维护时, 机组部件的有效役龄按原有速度继续增加; 当更换维护方式时, 部件有效役龄恢复至 0。引入有效役龄因子 a_γ ($\gamma=1, 2$) 来描述部件性能恢复的程度, $0 < a_2 < a_1 < 1$, 记 $\gamma=1, 2$ 分别为小修和大修的维护方式。设维护累计次数为 n , 第 $k-1$ 次维护和第 k 次维护的时间间隔为 T_k 。在文献[20]基础上, 考虑不同的维护方式后, 第 k 次维护时有效役龄 η 为:

$$\eta = \begin{cases} T_k & k=1 \\ \sum_{\gamma=1}^2 \sum_{w=1}^{n-1} a_\gamma T_w + T_k & k=2, 3, \dots, n \end{cases} \quad (14)$$

依据式(14), 在不同维护方式下, 部件有效役龄随时间变化的关系见附录 A 图 A2。由图可知, 部件有效役龄受之前预防性维护次数及其维护方式影响, 设机组自正常状态至状态评估起始时刻间共进行了 n_1 次小修和 n_2 次大修, 且 $n_1 + n_2 = n$, 以 n_γ 表示预防性维护在采用维护方式 γ 下的维护次数期望, 累计运行时间为 t , 则部件的有效役龄 η 为:

$$\eta = t - \sum_{k=1}^n T_k^\gamma + \sum_{\gamma=1}^2 \sum_{k=1}^n a_\gamma n_\gamma T_k^\gamma \quad (15)$$

式中: T_k^γ 为维护方式 γ 下第 $k-1$ 次维护与第 k 次维护时间间隔。设维护方式向量 $A = [a_1, a_2, a_3, a_4, a_5]$, 其中任意元素值 $a_u \in \{0, 1, 2, 3\}$, 4 个元素分别表示不维护、小修、大修、更换, 结合由 2.3 节模型得出状态评估时机组部件处于各状态的概率向量 P , 小修和大修次数的期望分别为:

$$n_1 = n(1 - PA^T) \quad (16)$$

$$n_2 = nPA^T \quad (17)$$

由于机组的重要部件是串联系统, 且旋转部件服从威布尔分布, 在第 k 次预防性维护周期内, 部件形状参数 β 下机组有效役龄时刻 $\eta_k^{\beta-1}$ 下的故障次数总期望 E_k 为:

$$E_k = \int_{T_{k-1}}^{T_k} \frac{\beta}{\theta^\beta} \eta_k^{\beta-1} dt \quad (18)$$

式中: θ 为尺度参数。进行 n 次预防性维护前,故障总次数期望 E 为:

$$E = nE_k \quad (19)$$

在结合机组状态评估结果确定的小修、大修次数的期望、有效役龄和故障总次数期望 E 的基础上,本文需考虑对传统部件预防性维护费用进行修正。

1) 预防性维护费用。

部件预防性维护费用 C_{pm} 与每种维护方式的次数和平均每次维护所需费用有关,由于维护费用期望可由 $C_\gamma P^T$ 表示,则 C_{pm} 为:

$$C_{pm} = \sum_{\gamma=1}^2 n_\gamma C_\gamma P^T \quad (20)$$

式中: C_γ 为机组在不同状态下采用维护方式 γ 时的费用,其综合考虑部件不同状态下所需维护租赁船只、人员数量及维护耗材等费用。

2) 预防性更换费用。

部件预防性更换费用 C_{pr} 与更换次数及更换费用有关,则 C_{pr} 为:

$$C_{pr} = c'E \quad (21)$$

式中: c' 为单次部件更换费用。

3) 维修停机损失费用。

通过引入反映单位时间停机损失的容量因子 r 量化单位停机损失费用,则 C_{lm} 为:

$$C_{lm} = \chi \sum_{\gamma=1}^2 r V n_\gamma \bar{T}_{lm}^\gamma \quad (22)$$

式中: χ 为上网电价; V 为机组容量; $\bar{T}_{lm}^\gamma$ 为维护方式 γ 下平均维护时间。

4) 更换停机损失费用。

更换部件时停机损失费用 C_{lr} 与停机时长、故障次数和单位时间发电量有关,则 C_{lr} 为:

$$C_{lr} = \chi r V E \bar{T}_{lr} \quad (23)$$

式中: $\bar{T}_{lr}$ 为部件平均更换时间。

机组维护周期内维护总费用由预防性维护费用 C_p 和维护损失费用 C_l 构成,以各状态的概率 P 为维护策略制定的依据建立海上风电机组预防性维护总费用的目标函数为:

$$\operatorname{argmin}_{A, T} C = C_p + C_l \quad (24)$$

单次预防性维护费用 C_p 由预防性维修和预防性更换费用构成,维护损失费用 C_l 由维修损失和更换停机损失费用构成。考虑预防性维护方式不同,引入维护方式决策因子 ξ ($\xi=1$ 时进行预防性维护, $\xi=0$ 时进行预防性更换),则 C_p 与 C_l 分别如式(26)和式(27)所示。

$$C_p = \xi C_{pm} + (1-\xi) C_{pr} \quad (25)$$

$$C_l = \xi C_{lm} + (1-\xi) C_{lr} \quad (26)$$

3.2 海上风电机组多部件成组维护模型

在维修窗口期内,对机组若干部件进行成组维护具有实际的工程意义。在单次出海维护作业时,

部分部件的维护时刻相对于该部件的最优预防性维护计划提前,但另一方面,滞后于预防性维护时刻的部件在运行中累积风险,则由机组部件提前维护或延迟维护产生的变动费用为:

$$\Delta C = \delta C_a + (1-\delta) C_d \quad (27)$$

式中: C_a 为提前维护浪费费用; C_d 为延迟维护惩罚费用; δ 为成组方式因子,其取值为1时,提前对部件维护,其取值为0时,延迟维护。

成组维护牺牲了部分部件维护的经济性要求,对故障前提前维护的部件,设在时刻 x 进行出海维护作业,则 $T-x$ 时间段采用维护方式 γ 造成的提前维护浪费费用 C_a 如式(28)所示。

$$C_a = C_\gamma P^T \int_x^{T_w} \frac{\beta}{\theta^\beta} \eta_k^{\beta-1} dt \quad T_w \geq x \quad (28)$$

式中: T_w 为部件最优预防性维护周期。式(28)中不定积分表示故障次数的期望函数,其与出海维护时刻的选择有关。同理,延迟维护惩罚费用 C_d 为:

$$C_d = C_\gamma P^T \int_{T_w}^x \frac{\beta}{\theta^\beta} \eta_k^{\beta-1} dt \quad T_w < x \quad (29)$$

在维护窗口期,在当前机组状态确定的最优维护周期的基础上,计及待维护部件的调整费用,以长期维护总费用最小为目标,以出海维护部件时间小于当年有效维护时常为约束,以部件维护成组维护方案为求解目标,构建机组成组累计维护费用模型如式(30)所示。

$$\begin{cases} \min_{\psi} C = \sum_s (C_s + \Delta C_s) \\ \text{s.t.} \quad \sum T_s \leq T' \end{cases} \quad (30)$$

式中: ψ 为成组维护的部件集合; s 为部件标识; C_s 和 ΔC_s 分别为部件 s 本身维护费用和变动费用; T_s 为部件 s 维护时长; T' 为出海作业时间。

4 模型求解

模型求解的目标是在对机组各状态空间数据学习最优字典的基础上,评估机组处于各状态的概率向量,并基于策略迭代算法制定各部件下次最优预防性维护策略。再制定出各部件长期维护安排后,以总维护费用最小为目标,以日维护时长为约束,求解出长期最优的部件成组方案。预防性维护策略的求解流程如图2所示。

5 仿真分析

以某海上风电场3 MW 机组为例,结合海上风电机组运维的现场经验,针对故障率较高及停机时间长、维护费用高的关键部件,选择机组的叶片、齿轮箱、主轴和发电机作为仿真对象,通过分布函数线性化的最小二乘估计法拟合,并以 Anderson-Darling 值最小作为判定部件寿命分布的指标,结果表明,仿真旋转部件的性能衰退过程均符合威布尔分布。部




图2 预防性维护策略求解流程

Fig.2 Solution process of preventive maintenance strategy

件维护费用包含维护固定费用和可变费用。其中,维护固定费用计及维护所需人员和船只租赁费用,人员工资为 300 元/h,船只费用为 50000 元/d,维护时所需人数为 3 人,更换时所需人数为 12 人。每次维护时间为 8 h,上网电价为 0.8 元/(kW·h)。机组在不同状态下,每次维护时的可变费用主要由部件维护费用和停机损失费用组成。结合实际现场维护情况,小修有效役龄因子 $a_1=0.9$,大修有效役龄因子 $a_2=0.6$ 。仿真所用叶片、齿轮箱、主轴承和发电机的威布尔分布参数和相关维护费用与时间依据文献[20]得出。

5.1 海上风电机组状态自适应评估

对历史状态空间中数据的初始字典学习是进行增量式学习的基础。在初始状态评估中,选取各部件初始故障诱因的状态数据作为初始训练集进行仿真实验,训练集由机组正常和各部件的轻度异常、中度异常、重度异常和故障的状态数据组成,每个状态的训练样本个数为 100;每组测试集均由 100 个样本构成,其中状态所占比例相同(即每类状态样本数量所占比例为 20%)。对每个部件分别进行测试,进行初始字典学习后状态自适应评估识别率见表 1。表 1 的结果表明,主轴承的识别效果最好,其识别率为 81%。此外,初始训练集的平均识别率为 74.5%。

为了获取蕴含新信息的状态数据,依据 U 检验的结果,以拒绝域中数据集作为状态增量数据。结

表 1 初始状态自适应评估识别率

Table 1 Recognition rate of initial state adaptive assessment

部件	故障原因	识别率 / %
叶片	叶片安全链断路	79
主轴承	冲击负荷过大引起裂纹缺陷	81
齿轮箱	管路老化导致齿轮油渗漏	70
发电机	接地碳刷磨损	68

合历史维护日志信息,分别两两计算不同故障诱因下机组状态数据的 $u_{1-\alpha/2}$,通过查询 t 界值表中双侧 α 的 U_1, U_2 ,根据假设检验结果,显著性水平 α 取 0.2。

在已有初始字典和检验标准值的基础上,结合状态数据,按故障发生的先后顺序,以各部件故障时的数据作为增量数据进行增量式学习,训练集中初始训练集和增量数据集的样本数量均为 100,对每个部件分别做测试,每组测试集样本数为 100,测试集中样本组成和机组状态自适应评估模型的识别结果见表 2。表中, IS_1, IS_2 表示增量训练集数据类型; ITS 表示初始训练集数据类型。

表 2 基于增量字典学习的海上风电机组状态自适应评估识别精度

Table 2 Recognition accuracy of state adaptive assessment of offshore wind turbines based on incremental dictionary learning

部件	训练集数据类型	训练集标签	测试样本构成 / %	识别率 / %
叶片	ITS	叶片安全链断路	50	88
	IS_1	叶片螺栓断裂停机	50	
主轴承	ITS	冲击负荷引起裂纹	50	85
	IS_1	游隙过小引发烧伤	50	
齿轮箱	ITS	管路老化导致油渗漏	30	77
	IS_1	本体轴承过渡段断裂	30	
	IS_2	锁紧盘法兰有裂纹	40	
发电机	ITS	接地碳刷磨损	30	71
	IS_1	接地环打火	30	
	IS_2	发电机超速	40	

由表 2 可知,经过增量字典学习后,测试集状态平均识别率为 80.25%,相较于未进行增量字典学习法平均识别率提升了 5.75%,识别效果较好。由于 k 近邻分类(KNN)和 AdaBoost 算法在训练速度和识别精度上有优势,本文将其与增量字典学习在机组状态评估识别率方面进行对比。其中,训练集为表 2 中各部件的所有故障类型数据组成(即包含 ITS、 IS_1 和 IS_2),测试集样本数为 100。仿真结果显示,采用 AdaBoost 和 KNN 算法评估机组状态的识别率分别为 69% 和 76%,而采用增量字典学习的识别率为 85%,验证了本文所提方法有一定的优势。

5.2 部件预防性维护策略

选取海上风电机组从 2011 年 1 月 1 日 00:00 至 2020 年 12 月 31 日 24:00 之间的状态数据验证所提

方法的有效性,其中,在2011年1月1日00:00开始对机组进行状态评估。在起始评估后的第0.35 a时,利用机组状态自适应评估模型进行发电机初始故障(接地碳刷磨损)字典学习,评估得出机组处于5个离散状态(正常、轻度异常、中度异常、重度异常、故障)的概率向量 $P=[0.18, 0.34, 0.26, 0.13, 0.09]$ 。另外,结合机组全年风速情况,统计得出容量因子取0.55;同时,依据历史维护日志中发电机实际更换时间和维修计划,维护总次数 n 取1。优化后维护策略向量为 $\{0, 1, 1, 0, 0\}$,即建议当前采用小修方式,且维护间隔为41 d,即在初始评估后的0.46 a后继续进行机组自适应评估状态并制定下次维护计划。主轴和齿轮箱的初始维护策略也采用同样的方法制定,各部件的初始维护计划见附录A表A1。在按原维护计划执行的基础上,结合机组当前状态评估结果,通过增量字典学习部件后续的故障诱因,提取故障特征,并逐次动态确定维护方式及维护间隔。其中,传统维护策略基于初始字典评估机组状态后制定,而基于状态自适应的维护策略则结合增量字典学习得到的状态评估知识库来制定。附录A图A3表示开始评估机组状态后10 a内,各部件传统和自适应预防性维护计划安排情况。依据图中传统维护策略和基于状态自适应的机组维护策略,分别计算起始状态评估后的10 a内的累计维护费用,如图3所示。




图3 2种维护策略下海上风电机组累计维护费用
Fig.3 Accumulated maintenance costs of offshore wind turbines under two maintenance strategies

由图3可知,机组在投运后,由于状态评估模型学习到的故障诱因单一,无法有效识别部件状态。虽然在前4.81 a内维护费用较少,但维护不足所带来的运行风险使得机组在后期采用频繁的大修和更换方式。仿真结果表明,在10 a内的原始累计维护费用高于本文所提方法,且截至初始状态评估后10 a,所提方法较原始维护策略费用下降了17.59%。

5.3 成组维护策略

为了获取机组部件最优成组维护的时刻,结合部件维护周期,在起始状态评估后的 $[7.7, 8.1]$ a时间段内,以天为单位滚动时间周期,对主轴承、发电机、齿轮箱和叶片采用成组维护,由于四部件成组维护时长难以满足日维护时长约束,仿真中枚举三部

件成组和两部件成组下的维护费用,在当次维护窗口期内考虑停机损失后,维护费用变化见附录A图A4。由图可知,三部件成组维护最优时刻起始状态评估时刻后7.73 a(即2821 d),发电机、齿轮箱、主轴承最优的维护方式均为小修。不同成组方案下在起始状态评估后 $[7.7, 8.1]$ a间最优维护时间及最优维护费用见表3,表中最优维护时间采用起始状态评估后的天数度量。

表3 不同成组方案下的最优维护时间及维护费用

Table 3 Optimal maintenance time and maintenance cost under different group schemes

成组部件	最优维护时间 / d	最优维护费用 / 万元
{发电机, 齿轮箱, 主轴承}	2820	166.35
{发电机, 齿轮箱, 叶片}	2836	183.61
{发电机, 主轴承, 叶片}	2874	143.86
{齿轮箱, 主轴承, 叶片}	2843	187.38
{发电机, 齿轮箱}	2828	116.29
{发电机, 主轴承}	2840	66.15
{发电机, 叶片}	2826	89.41
{齿轮箱, 主轴承}	2868	119.67
{主轴承, 叶片}	2573	92.58

由表3可知,在起始状态评估后的 $[7.7, 8.1]$ a维护时间窗内,推荐在第7.78 a(即第2840 d)时只对发电机、主轴承均采用小修的维护策略,此时,该次成组维护费用最小,其值为66.15万元。

由于在起始评估后的2.32 a(即第849 d)前,预防性维护安排仅制定了发电机、主轴承和叶片的维护计划,直到评估后的 $[2.32, 10]$ a内,所有仿真部件(发电机、齿轮箱、主轴承、叶片)的维护安排被完全制定,因此,选择从评估后的2.32 a开始计算最优成组维护计划。相较于对机组部件进行预防性维护,成组维护主要通过减少维护船只、人员和提高并网运行时间来节省总费用。截至初始状态评估后的10 a,累计节省费用为371.14万元。

5.4 灵敏度分析

在实际现场维护中,维护受机组当前状态、可及度等因素的影响,维护策略也应随之调整。

1) 维护次数。

海上风电机组当前状态受维护次数的影响,本文将更换部件后大修和小修的总次数用累积维护次数 n 表示。过多次数的出海维护会使部件有效役龄持续增长,当处于生命周期末端时,部件故障频发,维护费用也随之增加,甚至比采用更换维护方式的经济性低。在主轴承、发电机、齿轮箱分别更换后(有效役龄为0),采取不同维护方式下,部件维护费用累计维护次数变化如图4所示,图中,实线表示维修费用,虚线表示更换费用。

由图4可知,在机组重要部件实际更换后至起始状态评估这段时间中,由于有效役龄增加,经过多




图4 累计维护次数对维护费用影响情况

Fig.4 Impact of cumulative maintenance times on maintenance cost

次的维护(小修和大修)均会导致维护单部件预防性维护费用逐渐升高。叶片、主轴承、发电机、齿轮箱分别在维护5、5、5、7次后,采用更换维护方式比继续采用维护在维护费用方面更具优越性。此外,维护次数对齿轮箱的维护费用最敏感。

2) 可及性。

海上风电机组的维护可及性受海洋环境影响较大,因此,在实际维护工作中每次维护时间具有不确定性。同时为了兼顾维护安全性和实际维护工作量,本次仿真假设每日维护时长为8 h,在此基础上,当日维护时间分别相对增减25%和50%时,成组维护费用相对变化率如表4所示。

表4 日维护时长对成组维护费用的影响

Table 4 Impact of daily maintenance time on group maintenance costs

日维护 时长/h	日维护时长 变化率/%	预防性维护费用 变化率/%
4	-50	15.4
6	-25	6.6
8	0	0
10	25	-9.5
12	50	-17.1

由表4可知,随着日维护时长增加,预防性维护费用变化率降低。但当日维护时长变化率相对减少50%时,预防性维护费用变化率增加15.4%,这是因为大修时间较长,难以满足日维护时长的约束,无法成组维护的部件只能采用频繁停机、多次维护的策略,因而增加了巨大的维护费用。而日维护时长相对增加50%后,由于部件小修时间集中在3~6 h,每次成组维护的部件较多,预防性维护费用变化率降低17.1%。综上,为了降低预防性维护费用,建议将采用小修方式维护的各部件集中进行成组维护。

6 结论

本文针对机组新故障特征自适应提取及长短期维护配合问题,采用增量字典学习和SVM评估机组状态,并结合状态自适应评估结果,以全寿命周期维护费用最小为目标,协调单次出海维护计划,构建了

基于状态自适应评估的海上风电机组预防性维护模型,通过仿真分析得到如下结论:

1) 基于增量字典学习的海上风电机组自适应评估模型通过自适应更新状态评估知识库,实现对机组状态准确评估,相较未进行自学习的状态评估方法,机组状态自适应评估的平均识别率提升了5.75%;

2) 考虑了机组状态评估的自适应对维护费用的影响,与传统维护策略相比,本文所提方法的维护费用下降了17.59%;

3) 考虑了维护次数和可及性对维护费用的影响,对于已进行多次维护的重要部件,采用更换的维护方式相比于继续维修更有利于节省维护费用,此外,随着单次日维护时长增加,维护总费用降低,证明了维护总费用受维护次数和可及性的影响较大。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 徐潇源,王晗,严正,等. 能源转型背景下电力系统不确定性及应对方法综述[J]. 电力系统自动化,2021,45(16):2-13.
XU Xiaoyuan, WANG Han, YAN Zheng, et al. Overview of power system uncertainty and its solutions under energy transition [J]. Automation of Electric Power Systems, 2021, 45(16): 2-13.
- [2] LEE J. Global offshore wind report 2021[R]. Brussels, Belgium: Global Wind Energy Council, 2021.
- [3] BLANCO M. The economics of wind energy[J]. Renewable & Sustainable Energy Reviews, 2011, 13(6-7): 1372-1382.
- [4] 黄玲玲,曹家麟,张开华,等. 海上风电机组运行维护现状研究与展望[J]. 中国电机工程学报,2016,36(3):729-738.
HUANG Lingling, CAO Jialin, ZHANG Kaihua, et al. Status and prospects on operation and maintenance of offshore wind turbines[J]. Proceedings of the CSEE, 2016, 36(3): 729-738.
- [5] 郭慧东. 海上风电机组运行状态评价与维修决策[D]. 北京: 北京交通大学,2018.
GUO Huidong. Operation condition evaluation and maintenance decision of offshore wind turbine group[D]. Beijing: Beijing Jiaotong University, 2018.
- [6] AHMAD R, KAMARUDDIN S. An overview of time-based and condition-based maintenance in industrial application[J]. Computers & Industrial Engineering, 2012, 63(1): 135-149.
- [7] 李辉,胡姚刚,李洋,等. 大功率并网风电机组状态监测与故障诊断研究综述[J]. 电力自动化设备,2016,36(1):6-16.
LI Hui, HU Yaogang, LI Yang, et al. Overview of condition monitoring and fault diagnosis for grid-connected high-power wind turbine unit[J]. Electric Power Automation Equipment, 2016, 36(1): 6-16.
- [8] 郭鹏,王兆光. 基于高斯过程回归和双滑动窗口残差处理的风电机组主轴状态监测[J]. 电力自动化设备,2018,38(6):34-40.
GUO Peng, WANG Zhaoguang. Wind turbine spindle state monitoring based on Gaussian process regression and double moving window residual processing[J]. Electric Power Automation Equipment, 2018, 38(6): 34-40.
- [9] ESNARD F, BERTLING L. An approach for condition-based maintenance optimization applied to wind turbine blades[J]. IEEE Transactions on Sustainable Energy, 2010, 1(2): 77-83.
- [10] 赵洪山,张健平,程亮亮,等. 考虑不完全维修的风电机组状态-机会维修策略[J]. 中国电机工程学报,2016,36(3):701-708.
ZHAO Hongshan, ZHANG Jianping, CHENG Liangliang, et al.

- A condition based opportunistic maintenance strategy for wind turbine under imperfect maintenance[J]. Proceedings of the CSEE, 2016, 36(3): 701-708.
- [11] 赵洪山,李自立. 风电机组轴系的剩余寿命预估[J]. 电力自动化设备, 2020, 40(6): 70-75, 99.
- ZHAO Hongshan, LI Zili. Prognosis of remaining lifetime of wind turbine unit shafting[J]. Electric Power Automation Equipment, 2020, 40(6): 70-75, 99.
- [12] TIAN Zhigang, JIN Tongdan, WU Bairong, et al. Condition based maintenance optimization for wind power generation systems under continuous monitoring[J]. Renewable Energy, 2011, 36(5): 1502-1509.
- [13] SI Xiaosheng, LI Tianmei, ZHANG Qi, et al. An optimal condition-based replacement method for systems with observed degradation signals[J]. IEEE Transactions on Reliability, 2018, 67(3): 1-13.
- [14] 黄玲玲,符杨,任浩瀚,等. 基于状态信息的风电机组维护研究综述[J]. 中国电机工程学报, 2020, 40(21): 7065-7078.
- HUANG Lingling, FU Yang, REN Haohan, et al. Review of wind turbine maintenance based on condition monitoring systems[J]. Proceedings of the CSEE, 2020, 40(21): 7065-7078.
- [15] 蒋盛益,李霞. 一种改进的BIRCH聚类算法[J]. 计算机应用, 2009, 29(1): 293-296.
- JIANG Shengyi, LI Xia. Improved BIRCH clustering algorithm[J]. Journal of Computer Applications, 2009, 29(1): 293-296.
- [16] 王英立,陶帅,候晓晓,等. 基于MIV分析的GA-BP神经网络光伏短期发电预测[J]. 太阳能学报, 2020, 41(8): 236-242.
- WANG Yingli, TAO Shuai, HOU Xiaoxiao, et al. GA-BP neural network photovoltaic power generation short-time forecast based on MIV analysis[J]. Acta Energetica Sinica, 2020, 41(8): 236-242.
- [17] 孙红岩,姜雪峰. 智能诊断中诊断知识的实时自学习方法[J]. 重庆大学学报, 2010, 33(4): 21-25.
- SUN Hongyan, JIANG Xuefeng. Real-time self-learning method of diagnostic knowledge in intelligent diagnosis system[J]. Journal of Chongqing University, 2010, 33(4): 21-25.
- [18] LEI Tao, XUE Jiang, ZHOU Li, et al. Multiscale incremental dictionary learning with label constraint for SAR object recognition[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(1): 80-84.
- [19] 司马莉萍,舒乃秋,李自品,等. 基于SVM和D-S证据理论的电力变压器内部故障部位识别[J]. 电力自动化设备, 2012, 32(11): 72-77.
- SIMA Liping, SHU Naiqiu, LI Zipin, et al. Identification of interior fault position based on SVM and D-S evidence theory for electric transformer[J]. Electric Power Automation Equipment, 2012, 32(11): 72-77.
- [20] 符杨,许伟欣,刘璐洁,等. 考虑天气因素的海上风电机组预防性机会维护策略优化方法[J]. 中国电机工程学报, 2018, 38(20): 5947-5956.
- FU Yang, XU Weixin, LIU Lujie, et al. Optimization of preventive opportunistic maintenance strategy for offshore wind turbine considering weather conditions[J]. Proceedings of the CSEE, 2018, 38(20): 5947-5956.

作者简介:



符 杨

符 杨(1968—),男,江苏如东人,教授,博士,主要研究方向为城市电网规划、风力发电与并网技术等(**E-mail**:mfudong@126.com);

黄路遥(1995—),男,山东济宁人,硕士研究生,主要研究方向为海上风电运行维护策略(**E-mail**:luyao_h@163.com);

刘璐洁(1983—),女,山西太原人,讲师,博士,通信作者,主要研究方向为电力系统自动化、风电场并网分析与运行维护(**E-mail**:susiellj@163.com)。

(编辑 王欣竹)

Preventive maintenance strategy for offshore wind turbine based on state adaptive assessment

FU Yang¹, HUANG Luyao¹, LIU Lujie¹, WEI Shurong¹, REN Haohan², WANG Yi², TANG Gengpei²

(1. Department of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Shanghai Green Environmental Protection Energy Co., Ltd., Shanghai 200433, China)

Abstract: In order to solve the problems of incremental learning of fault characteristics and active maintenance for OWT(Offshore Wind Turbine), a preventive maintenance strategy for OWT based on state adaptive assessment is proposed. Firstly, the non-normal population hypothesis is used to test and quantify the information difference between the real-time state and the typical state of OWT, and the typical state characteristics of OWT are captured by the incremental dictionary learning. Then, an adaptive state assessment model of OWT is built based on support vector machine. Secondly, combined with the effective service life of the components, the component maintenance strategy is optimized with the probability vector of state as the decision constraints and the minimum single maintenance cost as the objective function. At the same time, the preventive maintenance model of OWT based on state adaptive assessment is established with the minimum total maintenance cost as the objective function and the daily maintenance time as the constraints, taking into account the loss caused by early or delayed maintenance when the components are grouped. Finally, an offshore wind turbine is taken as an example to verify the effectiveness of the proposed maintenance strategy, and the influence of maintenance times and accessibility on the maintenance strategy is analyzed.

Key words: offshore wind turbine; state space partition; incremental dictionary learning; state adaptive assessment; preventive maintenance

附录 A




Fig.A1 Initial state space division for offshore wind turbines




图 A2 不同维护方式对部件有效役龄影响

Fig.A2 Effect of different maintenance methods on effective service life of components

表 A1 部件初始维护策略及费用
Table A1 Maintenance strategy and cost of initial components

初始状态自适应评估后的时间/d	维护对象	状态评估概率阵	维护方式	维护间隔/d	维护费用/万元
816	叶片	[0.03,0.10,0.17,0.24,0.46]	大修	486	42.28
126	发电机	[0.18,0.34,0.26,0.13,0.09]	小修	41	21.28
282	主轴承	[0.07,0.08,0.11,0.35,0.39]	更换	297	132.09
871	齿轮箱	[0.22,0.41,0.25,0.07,0.05]	小修	420	49.73





图 A3 各部件预防性维护安排

Fig.A3 Preventive maintenance arrangements for each component



- 发电机、齿轮箱、主轴承均提前维护
- 发电机延迟维护、齿轮箱和主轴承提前维护
- 发电机和齿轮箱延迟维护、主轴承提前维护
- · - 发电机、齿轮箱、主轴承均延迟维护

图 A4 不同成组方案下的维护费用变化

Fig.A4 Variation in maintenance costs under different group scenarios