李娅楠, 张新生, 武春杨, 等. 寿命预测不确定下的海上风电机组机会性维护优化研究[J]. 安全与环境学报, 2026, 26(7): 2514 - 2526.

Li Yanan, Zhang Xinsheng, Wu Chunyang, et al. Optimizing opportunistic maintenance for offshore wind turbines: addressing uncertainty in life prediction[J]. Journal of Safety and Environment, 2026, 26(7): 2514 - 2526.

寿命预测不确定下的海上风电机组机会性维护优化研究*

李娅楠,张新生,武春杨,张振龙,苏 佳

(西安建筑科技大学管理学院,西安 710055)

摘 要:针对海上风电机组运行维护中寿命预测不确定导致的维护决策优化问题,提出一种融合多策略协同的维护决策优化方法。首先,引入动态概率化建模思想,构建基于时变概率分布的动态剩余寿命预测误差模型,以刻画预测误差的时变特性。其次,基于条件风险价值理论构建考虑预测误差非对称性的累计维护风险量化模型,并采用蒙特卡洛采样技术生成不确定场景集合,实现对潜在风险损失的评估。在此基础上,提出涵盖纠正性维护、预防性维护与机会性维护的分级维护策略,并以维护成本和运行风险最小化为双重优化目标,构建面向全生命周期评估的海上风电机组多目标维护优化模型。最后,采用非支配排序遗传算法(Nondominated Sorting Genetic Algorithm Ⅱ,NSGA - Ⅱ)对模型进行求解,实现维护策略和阈值组合的协同优化。案例结果显示,该融合多策略协同的维护决策优化方法不仅能有效降低维护成本,还能实现风险的精准量化,并在成本与风险之间取得合理平衡,为海上风电机组的运维管理提供可行方案。

关键词:安全工程;海上风电机组;寿命预测误差;机会性维护;条件风险价值;多目标优化

中图分类号:X947 **文献标志码**:A **文章编号**:1009-6094(2026)07-2514-13

DOI: 10. 13637/j. issn 1009-6094. 2025. 1228

0 引 言

作为可再生能源的重要组成,海上风电凭借其资源储量丰富、发电稳定性好、能量密度高等显著优势,近年来呈现快速发展态势[1-2]。然而,海上风电机组长期运行于高温高湿、强风巨浪的恶劣海洋环境中,面临维护窗口短、作业风险高、成本居高不下等突出问题[3-4]。据统计,海上风电场运维成本占全生命周期总成本的 30% 以上,显著制约了行业的经济效益[5-6]。在此背景下,通过建立智能维护策略体系,实现机组运维资源的科学配置,对于提升机组运行可靠性、保障风电场经济收益具有重要的理论意义和工程应用前景[7]。

海上风电机组维护技术经历了从以故障后修复为主的被动维修到基于时间周期的预防性维护的技术演进[8-9]。近年来,随着海上智能监测技术的发展,预测性维护技术通过融合多源传感器数据与智能算法,实现了海上风电机组设备状态的实时监测、性能退化精准预测和维护决策优化,为智能维护奠定了理论基础[10]。Wang 等[11]构建了将系统运行状态与维护策略相结合的决策框架,并根据监控信息决定是否进行维护或订购备件。Dong 等[12]通过建立剩余使用寿命(Remaining Useful Life,RUL)的概率密度函数转换模型,实现了备件订购时机的多目标优化。Ma 等[13]基于部件虚拟年龄可靠性预测改进了风力机的预防性维护策略。Lu 等[14]利用实时 RUL 预测结果,建立了基于成本率模型的关键部件最优预防性维护时间决策方法。然而,尽管上述研究在预测性维护方面已取得显著进展,但其建模与优化多数局限于单机层面,在海上风电场集群运维中会导致协同不足和资源配置效率低下。

针对多组件系统维护中的协同优化难题,McMorland 于 1963 年首次在多组件系统中提出了机会性维护策略[15],其核心思想是通过组件维护关联性实现任务协同规划与分组执行。随着海上风电产业向深远海、大型化方向发展,McMorland 于 2009 年最先将该策略引入海上风电领域[16],实现了对小型海上风电场的优化维护。海上风电机组的机会性维护策略通常采用混合维护模式,当风电场发生故障

* **收稿日期**: 2025 - 07 - 14

作者简介: 李娅楠,博士研究生,从事大数据分析与智能决策研究,lyn@ xauat. edu. cn;张新生(通信作者),教授,博士生导师,从事智能信息处理与模式识别,风险评估与智能决策研究,zhangxs@ xauat. edu. cn。

基金项目:陕西省创新能力支撑计划软科学项目(2024ZC - YBXM - 010);陕西省教育厅科学研究计划项目人文社科专项(24JK0131)

时,维护团队在实施纠正性维护的同时,充分利用维护窗口对故障机组关联部件及其他运行机组的高风险部件进行预防性维护,以实现故障修复与预防性维护资源的协同优化[17]。张晓红等[18]首次以风电场的同型多部件系统为对象,通过实时监测部件在多维退化空间中的状态,建立了考虑部件退化相关性的机会维修决策模型[19]。将组件劣化过程与海上环境条件相结合,构建了基于环境约束的系统级机会性维护决策方法[20]。在传统可靠度阈值方法基础上,引入子系统间的故障传播机制,提出了考虑故障风险水平的风电场机会性维护策略优化模型。修炳杰[21]从全生命周期成本角度出发,通过量化分析组件维护的经济依赖关系,提出了基于成本最优的维护阈值动态决策方法。这些研究显示,机会性维护策略在风电场运维优化中展现出良好的协同性和经济性。基于此,学者进一步将其与预测性维护相结合,以提升运维的经济性与可靠性[22]。基于实时 RUL 预测结果,考虑部件结构相关性和备件库存约束,建立了风电场成组维护优化模型。然而,基于 RUL 预测的维护决策模型通常建立在预测结果完全准确的理想假设基础上,忽略了测量噪声[23-24]、模型偏差[25-26]和环境干扰[27-28]等多源不确定性因素对预测结果的综合影响。这种理想化假设导致预测误差在决策过程中被放大,造成维护时机偏差和资源配置失衡,最终损害系统经济性[29]。

针对上述问题,本文综合考虑海上风电机组维护决策中的预测不确定性和实际维护特征,提出一种融合概率风险评估和多策略协同的海上风电机组机会性维护决策优化方法。该方法通过构建时变概率分布的动态 RUL 预测误差模型,实现对多源不确定性引起的预测偏差的量化表征,并结合条件风险价值理论和蒙特卡洛采样技术,评估不确定性下的潜在风险损失。在此基础上,建立涵盖直接维护成本、停机损失和风险成本的多目标优化决策框架,并采用 NSGA-Ⅱ算法求解该高维非线性优化问题,以期实现经济性与可靠性的动态平衡,进而为海上风电机组智能维护提供新的理论与实践路径。

1　剩余寿命预测不确定的风险量化

在工程实践中,海上风电机组设备 RUL 预测过程受多源不确定因素影响导致预测结果误差,这可能导致维护不足或过度维护,使维护决策偏离最优方案,进而增加运维成本并降低系统可靠性。为了应对这一挑战,研究将问题分解为两个核心子任务:一是对 RUL 预测误差进行数学表征,以量化误差的特性及演化规律;二是对预测不确定性进行建模,实现其在维护决策优化中的量化评估,以为后续多策略协同维护优化提供基础。

1.1　不确定性建模

海上风电机组关键部件 RUL 的预测易受环境波动、机械退化及监测设备测量误差等多源不确定性影响,从而产生预测误差。针对这一问题,本文通过建立动态概率分布模型,以实现对预测误差的系统量化与表征。首先,RUL 预测结果通常能够反映设备在运行过程中的退化规律与失效趋势:在组件的使用寿命周期内,随着运行时间的增加,其健康状态会逐渐退化,直至最终失效。为模拟组件的 RUL 预测结果,采用双参数威布尔分布对组件退化行为进行建模,并利用逆变换方法随机生成全生命周期寿命值 T_i。

$$T_i = \alpha_i \left[-\ln(1-\gamma) \right]^{\frac{1}{\varepsilon_i}} \tag{1}$$

式中　γ 为[0, 1]区间均匀分布的随机数;α_i 为尺度参数;ε_i 为形状参数。

在任意监测时刻 t,定义 RUL 百分比 $p_i(t)$ 表示为

$$p_i(t) = \frac{T_i - u_i(t)}{T_i} \tag{2}$$

式中　T_i 为实际寿命,d;$u_i(t)$ 为设备年龄,可表征已运行时间,d。

针对多源不确定耦合导致的预测误差,建立基于概率统计的误差分布模型。假设 RUL 百分比的预测值为 $\hat{p}_i(t)$,则预测误差 $e_i(t)$ 服从正态分布。

$$e_i(t) = \hat{p}_i(t) - p_i(t) \tag{3}$$

$$e_i(t) \sim \mathrm{N}(\mu_i(t), \delta_i(t)^2) \tag{4}$$

式中　$\mu_i(t)$ 为预测偏差;$\delta_i(t)$ 为标准差,可表征预测精度。

设备退化过程初期由于监测数据不足导致预测不确定性较大,随着退化进程的推进和监测数据的积累,模型精度逐步提升[30]。这一动态演化特性表明,预测误差具有阶段依赖性,其统计特征随设备退化过程的推进而不断变化。基于此特性,本文进一步建立时变正态分布误差模型,即将预测误差 $e_i(t)$ 建模为 RUL 的函数。

$$\mu_i(t) = a_\mu + b_\mu p_i(t) \tag{5}$$

$$\delta_i(t) = a_\delta + b_\delta p_i(t) \tag{6}$$

式中　a_μ 表示基准误差水平;a_δ 表示初始不确定性

程度；b_μ 和 b_δ 分别为接近失效时预测偏差和方差的收敛下限。根据此误差分布可随机生成不同退化阶段的预测误差样本，进而为维护决策提供概率化依据。

1.2 不确定性风险量化

在海上风电机组运维中，RUL 预测误差对经济损失的影响通常具有非对称性：高估 RUL 可能导致计划外停机和设备故障风险增加，而低估寿命则可能引发过早维护和资源浪费。为了量化这种非对称性经济影响，本文构建了分段非线性成本函数，即通过建立预测偏差与经济损失之间的非线性映射，刻画不同方向偏差所造成的经济损失差异，为维护决策提供精确依据。

当预测 RUL 显著低于实际 RUL[$\hat{p}_i(t) < p_i(t)$]时，将导致过早更换行为，产生三重经济损失：维护资源的直接浪费、机会成本损失、资金时间价值损失。针对该区间，成本函数采用二次形式，见式(7)。

$$L_o = \chi e_i^{\,2} + \upsilon \mid e_i \mid \tag{7}$$

式中 e_i 为预测误差；χ 为折现率因子，可反映资金的时间价值损失；υ 为机会成本折算因子，与电价呈正相关，可表征过早停机造成的收益损失。二次项体现了预测偏差增大引起的资源和资金损失加剧，线性项反映了机会成本的影响。

当预测 RUL 高于实际 RUL[$\hat{p}_i(t) > p_i(t)$]时，将引发维护不足，从而增加突发故障风险，产生多层次经济损失，包括基础设备维修成本、停机导致的发电损失以及系统层面的连锁反应损失。为表征该类风险的急剧增长特性，成本函数采用指数函数建模，见式(8)。

$$L_u = \alpha \exp(\tau e_i) + \kappa \tag{8}$$

式中 α 为基础风险系数，可表征设备故障风险的初始水平；τ 为风险增长因子，反映了预测误差累积对故障风险的非线性放大效应；κ 为应急维修基础成本，万元。

为提高风电场运维决策模型在不确定性环境下的鲁棒性，引入条件风险价值(CVaR)以量化极端情景下的尾部风险。在置信度水平 $\varphi \in [0,1]$ 下，CVaR 表示损失超过风险价值(Value at Risk，VaR)的条件期望为

$$R_\varphi^{\mathrm{CVaR}} = E[L(x,y) \mid L(x,y) \geqslant R_\varphi^{\mathrm{VaR}}] \tag{9}$$

$$R_\varphi^{\mathrm{VaR}} = \min\{\zeta \in \mathbf{R}: P(L(x,y) \leqslant \zeta) \geqslant \varphi\} \tag{10}$$

式中 R_φ^{VaR} 表示在概率测度 P 下的风险价值；$L(x,y)$ 为损失函数；ζ 为分位点阈值。

针对该优化问题，本文采用蒙特卡洛采样技术对原始连续分布进行随机采样，并离散化为 S 个场景，构建相应的线性规划模型，见式(11)和(12)。

$$R_\varphi^{\mathrm{CVaR}} = R_\varphi^{\mathrm{VaR}} + \frac{1}{1-\varphi}\sum_{s=1}^{S}[L(x,y) - R_\varphi^{\mathrm{VaR}}]^+ \tag{11}$$

$$\begin{aligned} &\text{s.t. } L(x,y) - R_\varphi^{\mathrm{VaR}} \leqslant \varphi \\ &\varphi \geqslant 0 \end{aligned} \tag{12}$$

式中 $[L(x,y) - R_\varphi^{\mathrm{VaR}}]^+ = \max\{L(x,y) - R_\varphi^{\mathrm{VaR}}, 0\}$；$S$ 为蒙特卡洛采样的场景数。

预测误差风险呈现典型的双模态分布特征：保守预测风险模态[$\hat{p}_i(t) < p_i(t)$]和激进预测风险模态[$\hat{p}_i(t) > p_i(t)$]，分别对应过早维护和延迟维护两种决策偏差。针对此特征，构建非对称 CVaR 风险量化模型，见式(13)～(15)。

$$R_i^{\mathrm{CVaR}} = R_{\varphi,i,L_o}^{\mathrm{CVaR}} + R_{\varphi,i,L_u}^{\mathrm{CVaR}} \tag{13}$$

$$R_{\varphi,i,L_o}^{\mathrm{CVaR}} = E[L_o \mid L_o \geqslant \gamma^{i,L_o}] \tag{14}$$

$$R_{\varphi,i,L_u}^{\mathrm{CVaR}} = E[L_u \mid L_u \geqslant \gamma^{i,L_u}] \tag{15}$$

式中 R_i^{CVaR} 表示非对称条件风险价值，用于综合评估预测误差风险；$R_{\varphi,i,L_o}^{\mathrm{CVaR}}$ 表示由于保守预测导致损失的过早维护 L_o 的条件风险价值；$R_{\varphi,i,L_u}^{\mathrm{CVaR}}$ 表示由于激进预测导致的延迟维护损失 L_u 的条件风险价值，即度量维护不足引发的故障风险。通过上述双模态刻画不同预测偏差下的非对称风险，实现对运维策略的精细化量化评估。

2 海上风电机组机会性维护决策框架构建

2.1 问题描述

针对海上风力涡轮机系统多部件间的强经济耦合特性，构建多阈值触发的机会性维护决策框架。假设风电场由 N 台同构型风力发电机组组成，每台机组包含 M 个关键功能组件。本文通过建立预防性维护、机会性维护和不完美维护的分级维护阈值决策矩阵，构建了多部件协同优化的动态维护框架。该框架采用周期性状态监测机制，以固定时间间隔 Δt 实时监测各组件，并动态更新 RUL 预测值 $\hat{p}_{ij}(t)$。基于 RUL 百分比 $\hat{p}_{ij}(t)$ 与预设阈值的动态比较结果，触发分级响应机制：当 $\hat{p}_{ij}(t)$ 低于失效阈值 T_{ij} 时，执行组件完全更换的纠正性维护；当达到预防性维护阈值 d_{PM} 的部件数量超过临界值 n_{PM} 时，实施批量更换的预防性维护。此外，采用主-从维护触发机制，当触发纠正性维护或预防性维护时，协同维护 $\hat{p}_{ij}(t)$ 处于机会性维护区间 $[d_{\mathrm{OM}}, d_{\mathrm{PM}})$ 的组件，或通过不完美修复 $\hat{p}_{ij}(t)$ 处于不完美维护区间 $[d_{\mathrm{IOM}}, d_{\mathrm{OM}})$ 的组件至中间状态。

针对不完美维护效果,引入 Kijima 虚拟年龄模型来描述修复行为对设备退化过程的影响。虚拟年龄 $r_{ij,s}$ 表示设备在第 s 次不完美维护后的“等效使用年限”,其更新公式为

$$r_{ij,s} = \theta_s(r_{ij,s-1} + \Delta\hat{t}_{ij,s}) \tag{16}$$

$$\Delta\hat{t}_{ij,s} = \begin{cases} t_{ij,s} - t_{ij,s-1} & s > 1 \\ t_{ij,s} & s = 1 \end{cases} \tag{17}$$

式中　$\Delta\hat{t}_{ij,s}$ 为相邻维护间隔期,d; $r_{ij,z}$ 表示第 S 次维护后的虚拟年龄,d; $\theta_s \in [0,1)$ 为维护效应因子。当 $\theta_s \to 0$ 时,维护效果趋近于“修复如新”;当 $\theta_s \to 1$ 时,则退化为“修复如旧”。设备虚拟年龄作为年龄参数代入式(2)即可获得维护后的 RUL。

维护决策框架的建立基于以下假设

(1)系统内所有部件的运行状态均可通过监测系统实时获取。

(2)部件性能随运行时间呈现连续退化特征,符合典型的设备老化规律。

(3)同型号部件具有相同的性能退化特征,且相同维护活动的实施成本与所属机组无关。

(4)人员、备件、运输设备等维护资源充足,均能满足多机组并行维护作业的需求。

(5)不考虑气象、政策、电力市场波动等外部因素对维护作业的影响。

2.2　多目标维护优化模型的目标函数

针对风电机组 RUL 预测中由于多源不确定性导致的预测偏差风险问题,以分级维护决策阈值(d_{PM} , d_{OM} , d_{IOM})作为决策变量,构建兼顾经济性与可靠性的多目标维护决策优化模型。该模型旨在通过加权最小化运营成本与风险成本,实现维护策略在成本效益与系统可靠性之间的最佳平衡。因此,优化目标函数定义为

$$\min_{(d_{\mathrm{PM}},d_{\mathrm{OM}},d_{\mathrm{IOM}})} \{(1-\beta)C_{\mathrm{total}} + \beta C_{\mathrm{risk}}\} \tag{18}$$

$$\text{s.t.}\quad 0 < d_{\mathrm{OM}} < d_{\mathrm{PM}} < d_{\mathrm{IOM}} < 1$$

$$L(x,y) - R_{\varphi}^{\mathrm{VaR}} \leqslant \varphi \tag{19}$$

$$\varphi \geqslant 0$$

式中　C_{total} 为全生命周期维护成本,万元; C_{risk} 为全生命周期风险成本,万元; $\beta \in [0,1]$ 为风险偏好系数,用于协调预期运营成本与风险成本之间的权衡关系,反映决策者对风险的容忍程度。

维护成本是影响海上风电机组全生命周期运维决策的关键经济要素,主要包括以下几个方面。

(1)直接维护成本。

直接维护成本 C^{M} 为不同维护策略下的直接经济投入,见式(20)。

$$C^{\mathrm{M}} = \sum_{j=1}^{M}\sum_{i=1}^{N}(c_{ij}^{\mathrm{FM}}x_{ij}^{\mathrm{FM}} + c_{ij}^{\mathrm{PM}}x_{ij}^{\mathrm{PM}} + c_{ij}^{\mathrm{OM}}x_{ij}^{\mathrm{OM}} + c_{ij}^{\mathrm{IM}}x_{ij}^{\mathrm{IM}}) \tag{20}$$

式中　c_{ij}^{CM} 、c_{ij}^{PM} 、c_{ij}^{OM} 和 c_{ij}^{IM} 分别表示第 j 台机组第 i 个部件的纠正性更换、预防性更换、机会性更换以及不完美修复成本,万元; x_{ij}^{FM} 、x_{ij}^{PM} 、x_{ij}^{OM} 、x_{ij}^{IM} 是二进制变量,用于标识是否执行相应维护操作。

(2)间接经济损失。

间接经济损失主要包含两类发电收益损失:突发故障导致的非计划停机和维护作业引起的计划停机。基于此,总停机时间 T_{SD} 计算为

$$T_{\mathrm{SD}} = T_{\mathrm{F}} + T_s \tag{21}$$

$$T_{\mathrm{F}} = \sum_{j=1}^{M} t_{ij}^{\mathrm{F}}x_{ij}^{\mathrm{FM}} \tag{22}$$

$$T_s = \sum_{j=1}^{M} t_j^s \tag{23}$$

式中　T_{F} 表示故障导致的停机时间,d; T_s 为第 s 次维护的最长停机时间,d; t_{ij}^{F} 是涡轮机中存在组件故障导致的停机时间,d。此外,在多机组协同维护场景下,系统整体停机时间的确定遵循关键路径法则,由各并行维护任务中的最大耗时决定,即 $t_j^s = \max\limits_{0\leqslant i\leqslant N}\{t_i^{\mathrm{IM}}, t_i^{\mathrm{OM}}, t_i^{\mathrm{PM}}, t_i^{\mathrm{CM}}\}$ 。

基于上述停机时间,构建发电损失成本(C^{G})模型,见式(24)。

$$C^{\mathrm{G}} = c_{\mathrm{d}}T_{\mathrm{SD}} \tag{24}$$

式中　c_{d} 为单位电价,元/h; T_{SD} 为总停机时间,d。

(3)资源消耗成本。

海上风电机组维护的资源消耗成本主要来源于大型特种设备使用和专业技术人员投入。船舶运营成本 C^{V} 包括固定运维费用和用于航线规划、设备调试及人员培训等准备工作的专项动员费用,见式(25)。

$$C^{\mathrm{V}} = \sum_{j=1}^{M} x_j^{\mathrm{R}}(c^{\mathrm{fix}} + c^{\mathrm{cr}})T_s \tag{25}$$

式中　c^{fix} 表示包含船舶日常运维、停泊等基础性固定成本,万元; c^{cr} 为专项动员成本,万元; x_j^{R} 为表征机组维护需求的二进制变量,维护时取为 1,否则为 0。

技术人员成本 C^{P} 采用基于作业时间的人力资源成本估算方法计算,表达式为

$$C^{\mathrm{P}} = n_{\mathrm{p}}c^{\mathrm{p}}T_s \tag{26}$$

式中　c^{p} 为技术人员单位时间费用,元/h; n_{p} 为技术人员配置数量。

(4)惩罚成本。

针对机会性维护引发的预防性维护计划偏移问题,建立基于时间偏移量(C^{PL})的非线性惩罚成本函数模型,见式(27)。

$$C^{\mathrm{PL}} = \sum_{j=1}^{M}\sum_{i=1}^{N}\left(\frac{t_{ij}^{\mathrm{act}}}{t_{ij}^{\mathrm{PM}}}\vartheta_i(t_{ij}^{\mathrm{PM}} - t_{ij}^{\mathrm{act}})\right) \tag{27}$$

式中 t_{ij}^{PM} 为机组 j 的组件 i 原定的预防性维护时刻;t_{ij}^{act} 为实际执行维护的时刻;$t_{ij}^{\mathrm{PM}} - t_{ij}^{\mathrm{act}}$ 为维护时间偏移量,用于量化实际维护行为相对于计划安排的偏离程度;ϑ_i 为惩罚系数。

风电机组维护决策需考虑经济依赖性特征,主要体现在运输成本分摊、设备共享效益、人力资源协同利用和管理效率提升等。基于经济依赖性特征,构建维护成本率评估模型,见式(28)。

$$C_{\mathrm{u}} = \frac{\sum_{k=1}^{K}(C^{\mathrm{M}} + C^{\mathrm{G}} + C^{\mathrm{V}} + C^{\mathrm{P}} + C^{\mathrm{PL}})}{S} \tag{28}$$

式中 C_{u} 为考虑经济依赖性后的单位时间平均维护成本,万元/a;S 为设计寿命,a;K 为维护周期总数。

考虑到风电机组多组件串联运行的系统特性,采用极大极小准则进行系统级风险聚合,见式(29)。

$$R_{jk}^{\mathrm{sys}} = \max_{i\in M}\{R_{ij,k}^{\mathrm{CVaR}}x_{ij,k}\} \tag{29}$$

式中 R_{jk}^{sys} 为机组 j 在第 k 个维护周期的风险成本,万元;$R_{ij,k}^{\mathrm{CVaR}}$ 和 $x_{ij,k}$ 分别表示机组 j 的组件 i 在第 k 个维护周期的风险成本和维护状态指示函数。

为全面评估风电场的长期运行风险,建立全生命周期风险累计模型,见式(30)。

$$C_{\mathrm{risk}} = \sum_{k=1}^{K}\sum_{j=1}^{M}R_{jk}^{\mathrm{sys}} \tag{30}$$

3 基于 NSGA-Ⅱ的维护策略优化

针对风电机组维护决策模型的非线性与多目标优化特性,采用 NSGA-Ⅱ算法对多目标优化问题进行求解。该算法通过 3 个核心机制实现优化:基于帕累托支配关系的快速非支配排序技术,实现对解集的精准分层;计算目标空间拥挤度距离,可有效保证解的分布均匀性;基于精英保留策略,保障优良个体的代际传承[31]。上述机制的协同作用使 NSGA-Ⅱ能在复杂约束条件下同时兼顾维护成本与系统可靠性,实现对多策略、多阈值维护方案的高效优化,为海上风电机组的维护决策提供可靠且可行的最优解。图 1 展示了 NSGA-Ⅱ算法的求解过程。

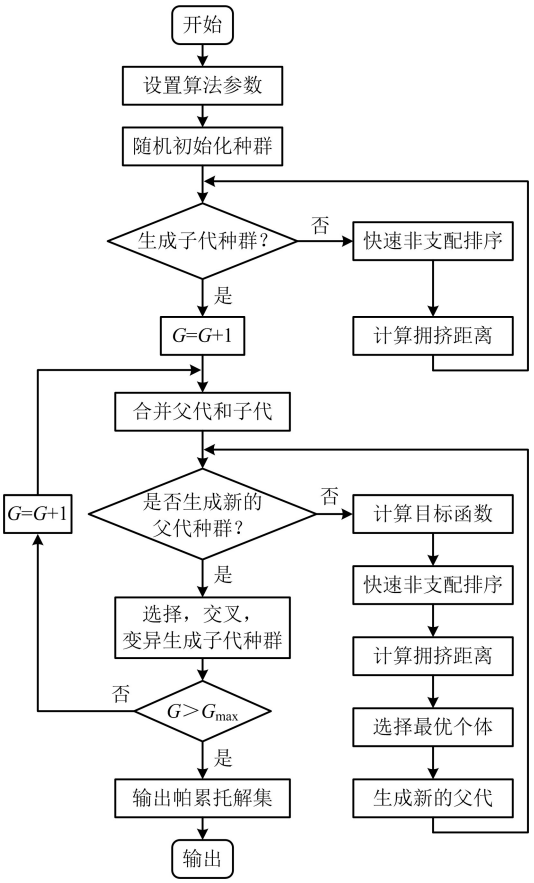

图 1 NSGA-Ⅱ的流程图

Fig. 1 Flowchart of NSGA-Ⅱ

步骤 1:初始化威布尔分布参数、总仿真周期 T_{total} 和决策时间间隔 Δt 等模型参数,并配置 NSGA-Ⅱ算法的相关参数。

步骤 2:采用实数编码方式随机生成规模为 M 初始种群 P_0,其中每个个体对应一个完整的维护策略方案。设置初始迭代代数 G 为 1。

步骤 3:根据维护决策评估模块计算种群个体的多目标适应度,包括维护成本、系统可用率等指标,并采用非支配排序分级评价种群个体。

步骤 4:通过选择、交叉及变异等遗传操作生成子代种群 Q_0,经可行性校验后与父代种群合并形成规模为 $2M$ 的临时种群 $R_t = P_t \cup Q_t$。

步骤 5:对合并种群 R_t 行快速非支配排序和拥挤距离计算,筛选出前 M 个最优个体并构成新一代种群 P_{t+1}。

步骤 6:判断是否达到终止条件。当进化代数 G 达到最大迭代次数 $G_{\max}$ 时终止迭代,输出帕累托最优解集。否则 $G = G + 1$,返回步骤 3 继续

优化。

4　数值实例

4.1　场景设置

针对实测数据获取难题,采用 5 台相同型号的 1.5 MW 风力机构成的典型海上风电场作为研究对象开展运维优化评估[32],机组关键参数见表 1。每台机组简化为包含齿轮箱、发电机、转子叶片和主轴承的串联可靠性模型,设计寿命为 15 a[33-34],部件的分布参数和维护参数见表 2。

RUL 预测误差分布参数设定是:均值误差 a_μ 和标准差 a_δ 分别为 0.1 和 0.03,峰值误差 b_μ 和峰度误差 b_δ 分别为 0.002 和 0.001。折现率因子 χ 设置为 0.1;机会成本折算因子 υ 为 0.3;基础风险系数 α 为 5 万元/MW,风险增长因子 τ 为 0.2;应急维修基础成本 κ 为组件纠正性维护费用和停机损失之和[30]。蒙特卡洛采样次数设定为 500 次。维护效应因子 θ_s 设定为 $0.6\exp(-0.3k)+0.5$;k 为不完美维护次数。预防性维护临界值 n_{PM} 为 3。不完美维护最大实施次数为 3 次。决策时间步长 Δt 为 3 个月;人工费率设定为 300 元/h;单位电价为 0.8 元/(kW·h);船舶租赁费用为 40 万元/d。

4.2　最佳维护策略

本文采用 NSGA-Ⅱ算法求解多目标优化问题,设置种群规模 60、最大进化代数 50。遗传操作采用高斯变异和中值交叉,突变和交叉概率分别设定为 0.1 和 0.9[35]。针对多目标函数的尺度差异问题,通过最大最小归一化处理。图 2 展示了优化过程中的目标函数的收敛特性和种群进化动态。

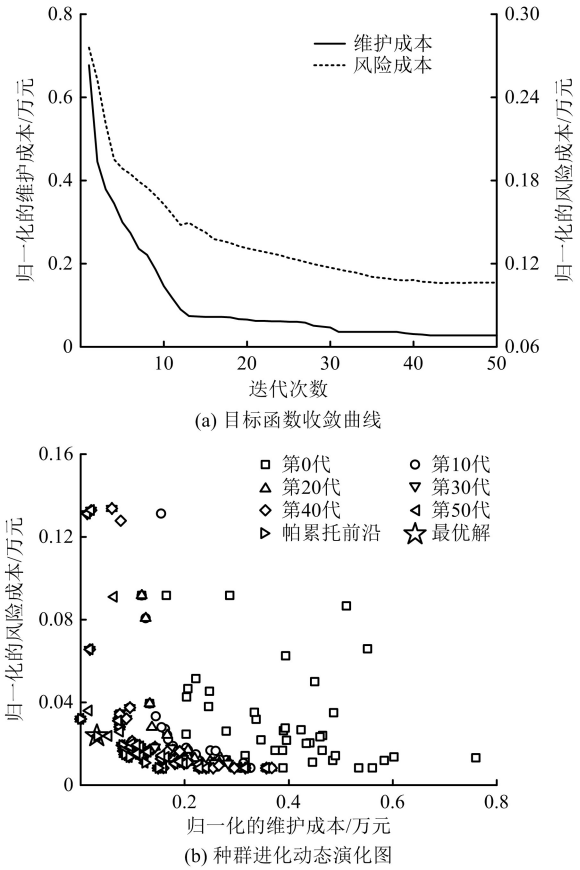

图 2　优化过程与种群演化可视化图

Fig. 2　Visualization of optimization process and population evolution

表 1　涡轮机参数

Table 1　Turbine parameters

额定功率/MW	转子直径/m	切入风速/(m·s^{-1})	额定风速/(m·s^{-1})	截止风速/(m·s^{-1})	最小转速/(r·s^{-1})	额定转速/(r·min^{-1})
1.5	163.44	3	11.7	25	5	10

表 2　部件的分布参数和维护参数

Table 2　Distribution parameters and maintenance parameters of components

组件	尺度参数/d	形状参数	维护成本/万元			维护持续时间/h		
			CM	PM	OM	CM	PM	OM
变速器	2 400	3	184	40	4	1 848	176	64
变速器	2 400	3	184	40	4	1 848	176	64
发电机	3 750	2	16	9.6	1.6	496	120	64
主轴承	3 300	2	48	20	2.4	648	192	56

注:CM 代表纠正性维护;PM 代表预防性维护;OM 代表机会性维护。

图 2(a)的目标函数变化曲线显示,在优化初期,维护成本指标呈指数下降趋势,从 0.7 快速下降至 0.1 以下,同时风险指标也从 0.27 同步降低至 0.14 左右,实现了快速收敛。在中期优化阶段,维护成本和风险成本下降速率明显减缓,表明模型进入最优解邻域,后续进行局部精细搜索。在优化后期,成本与风险指标分别稳定在 0 和 0.1 附近,形成稳定的帕累托前沿解集。从图 2(b)可以看出,初始种群在目标空间中呈现随机分布状态。随着进化代数增加,种群逐渐收敛于帕累托前沿。本文采用线性加权法对帕累托前沿进一步筛选,最终确定决策变量(d_{PM} , d_{OM} , d_{IOM})的全局最优解为(0.049, 0.123, 0.310),其对应的维护策略可实现 222.75 万元/a 的维护成本和 214.73 万元/a 的风险成本。

为了更直观地展示优化结果的工程适用性,图 3 展示了基于 NSGA-Ⅱ多目标优化算法求解的海上风电机组全生命周期机会性维护规划方案,其中垂直虚线表示风电场维护时刻。

如图 3 所示,风电机组 RUL 预测结果波动显著,反映了海上环境的多源不确定性影响。在全生命周期仿真中,动态维护决策模型规划了 7 次机会性维护作业。相邻维护作业之间的时间间隔分布在 10~40 个月的合理范围内,既避免了资源浪费又控制了可靠性风险。该策略实现了维护时机与资源的协同优化,有效平抑了资源需求峰值。

4.3 维护策略的比较

为了验证所提风电机组维护策略的优越性,本文选取 4 种典型维护策略作为基准方法进行对比分析。基准策略包括:(1)纠正性维护(Corrective Maintenance,CM)策略,即被动维护方式,仅在部件完全失效时采取被动维修措施;(2)定期维护(Time Based Maintecance,TBM)策略,即采用固定周期的计划性维护方案,维护间隔设定为 1 a;(3)预测性维护(Predictive Maintenance,PDM)策略,通过实时监测关键部件的 RUL,并基于预设阈值实现主动维护决策;(4)预测性机会性维护(Predictive Opportunity Maintenance,POM)策略,即在策略 3 的基础上引入机会性维护机制,利用系统停机窗口执行附加维护操作。为保证对比公平性,以上基准策略采用与所提策略相同的预防性阈值和机会性维护阈值。本文从维护操作次数和维护成本两个维度对比了所提策略与基准策略的性能差异,并以各基准策略为独立参照,评估所提方法的改进幅度,结果见表 3。

仿真结果表明,本文提出的鲁棒机会性维护策略具有显著优势。在 15 a 的运行周期内,该方法的

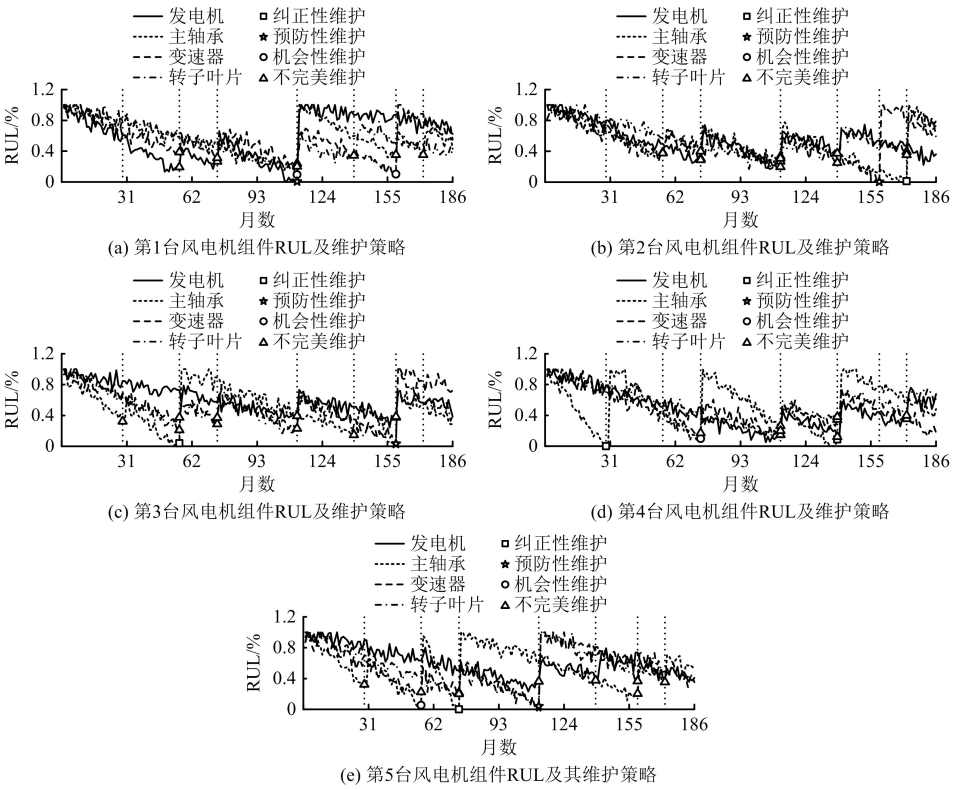

图 3 海上风电机组全生命周期维护规划方案

Fig. 3 Full life cycle maintenance plan for offshore wind turbines

总维护成本仅为 222.75 万元,分别较传统 CM、TBM、PDM 和 POM 策略降低了 88%、85%、73% 和 66%,停机成本也分别降低了 49%、92%、70% 和 48%。传统维护策略要么依赖事后修复导致成本过高,要么采用固定周期维护造成资源浪费,或仅基于阈值预测忽略环境不确定性,均难以兼顾经济性与可靠性。相比之下,本文方法通过融合机会窗口和分级维护的决策机制,优化了高成本维护时机,减少了非必要维护频次和停机时间,实现了全生命周期成本最小化与可靠性提升,验证了策略在平衡经济性与可用性方面的优越性。

4.4　敏感性分析

为考察决策周期、修复效用因子、预测精度和风险规避系数等关键参数对维护策略性能的耦合影响,通过敏感性分析探究各关键参数对维护成本、系统可用性及资源配置效率的影响规律。

(1)决策周期。

决策周期直接影响维护时机选择,过短会增加维护频率,过长则可能错过最佳维护窗口。表 4 对比了传统 TBM 策略与本文策略在不同决策周期下的成本差异。

结果显示,两种策略均在决策周期为 3 个月时达到最优经济性平衡点,本文所提策略的维护成本仅为传统 TBM 的 14.76%。当决策周期超过 3 个月时,非计划维修成本和间接发电量损失显著增加。当决策周期延长至 24 个月时,两种策略维护次数均减少,但由于设备故障未能得到及时处理,导致停机成本分别是 3 个月的 4.42 倍和 3.02 倍。反之,当决策周期缩短至 1 个月时,虽然停机成本分别降低了 54.12% 和 32.38%,设备可靠性得到保障,但是维护次数显著增加导致总成本分别增长 28.08% 和 136.56%,表明过度维护同样不利于运营成本优化。

表 3　不同维护策略的维护效果对比

Table 3　Comparison of maintenance effects under different maintenance strategies

策略	维护次数				停机成本/万元	维护成本/万元	改善率/%
	纠正性更换	预防性更换	机会性更换	不完美修复			
CM	29	—	—	—	58.39	1 806.34	88
TBM	22	—	—	—	348.88	1 508.82	85
CBM	—	37	—	—	97.50	835.07	73
POM	9	8	15		57.29	655.57	66
本文方法	5	6	4	51	29.64	222.75	

注:“—”为未执行该维护操作。

表 4　不同维护间隔下的成本对比

Table 4　Cost comparison under different maintenance intervals

决策周期/月	TBM			本文方法		
	维护次数	停机成本/万元	维护成本/万元	维护次数	停机成本/万元	维护成本/万元
1	30	149.59	1 932.64	8	26.55	526.95
2	27	233.90	1 723.20	7	26.85	452.47
3	22	348.88	1 508.82	5	29.64	222.75
4	21	374.76	1 856.92	6	53.12	309.32
5	23	404.06	1 936.63	5	54.85	372.71
6	23	423.43	1 970.87	4	60.85	408.05
12	13	1 097.56	2 198.50	4	65.14	514.61
18	9	1 251.95	2 253.95	3	74.55	513.71
24	8	1 544.46	2 367.12	3	116.52	543.62

由此可见,3 个月的决策周期在维护频次、停机成本与维护成本三者之间实现了最优协同。

(2)不完美维护效应因子。

不完美维护效应因子 θ_s 是反映维护后设备性能恢复程度的关键参数,其取值直接影响维护策略的有效性。为探究 θ_s 对系统性能的影响机制,本文探讨了不同 θ_s 对系统可用性和维护成本的动态影响规律,结果见图 4。其中,系统的可用性由停机成本来体现。

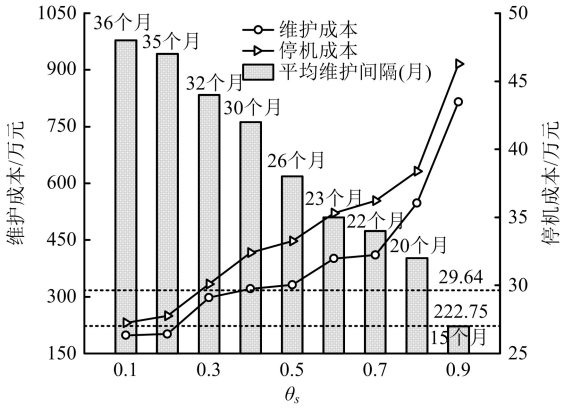

图 4 不完美维护效应因子下的维护成本结果

Fig. 4 Maintenance cost results under the imperfect maintenance effect factor

图 4 显示,当 θ_s 处于[0.1, 0.2]的高效用区间时,设备状态恢复率较高,系统可用性较高,停机成本和维护成本均较低。虽然长期保持完美维护状态在理论上可获得最佳维护效果,但不符合工程的实际情况。当 θ_s 降低至中等效用区间[0.3, 0.5]时,设备状态恢复率有所下降,维护间隔缩短至 38 ~ 44 个月,停机成本和维护成本分别较 θ_s = 0.1 时增长 10.42% 和 50.67%,且呈现出明显的边际效益递减特征。当 θ_s 进一步减小至[0.6, 0.9]的低效用区间时,设备状态恢复效果较差,平均维护间隔缩短至 27 ~ 35 个月,频繁的维护导致停机成本激增至 θ_s = 0.1 时的 1.29 至 1.69 倍。基于上述发现,本文采用随维护次数增加维护效应递减的动态调整机制:初期采用较高 θ_s 以保证设备可靠性;随着维护次数增加,θ_s 逐步降低以控制成本。由图 4 可以看出,该策略能够在保证设备可靠性的同时,使维护成本和停机成本保持在较低水平,提高系统的整体经济效益。

(3)风险偏好系数。

风险偏好系数 β 作为表征决策者风险态度的关键指标,对维护策略的选择具有直接影响。图 5 展示了不同 β 下最优策略的演化规律,可揭示风险态度与维护决策之间的内在关联。

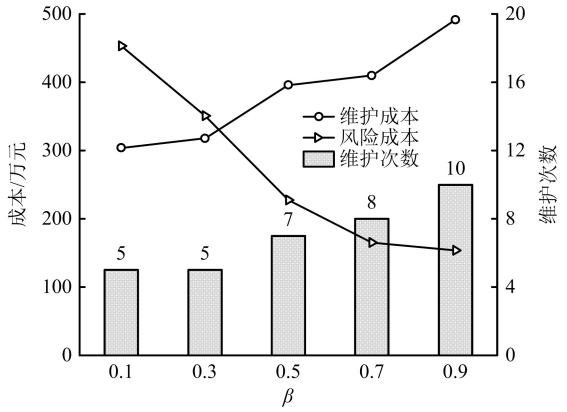

图 5 不同风险偏好下维护成本与风险成本的权衡关系

Fig. 5 Relationship between maintenance costs and risk costs under different risk preferences

图 5 显示,当 β = 0.1 时,呈现风险中性特征,维护频次最低、风险成本最小而维护成本最高。随着 β 增长至 0.5,风险规避增强使风险成本快速下降 49.80%,维护成本上升 554.76%,显示适度风险规避可有效降低不确定性风险。当 β 从 0.5 增长至 0.9 时,风险成本下降趋缓,维护成本稳定增长,表明过度风险规避效果有限。在 β = 0.9 时,系统进入强风险规避区域,风险成本达最低,较基准水平降低 66.09%,但维护成本升至最高,较基准增长 61.68%,表明极端风险规避策略虽然能有效控制风险损失,但需要付出较高的常规维护代价。由此可见,维护决策本质是风险成本与维护成本的动态权衡:风险中性策略接受更高风险以节省维护成本,而风险规避策略通过增加维护频次降低风险,但需承担更高维护代价。

(4)预测精度。

为评估预测精度对维护策略的影响,基于海上风电机组运行特性构建了 5 种典型误差分布场景。

场景 1:模拟理想监测条件下的预测情况(a_μ = 0.05, a_δ = 0.02),反映传感器精度高、工况稳定的理想状态;

场景 2:考虑复杂工况下的随机干扰(a_μ = 0.05, a_δ = 0.05),表征环境噪声等因素造成的预测波动;

场景 3:针对数据-模型失配问题(a_μ = 0.15, a_δ = 0.02),揭示参数偏差导致的系统误差;

场景 4:模拟极端工况(a_μ = 0.15, a_δ = 0.05),体现多物理场耦合的复合不确定性影响;

场景 5:本文采用的常规基准($a_\mu = 0.1$, $a_\delta = 0.03$, $b_\mu = 0.002$, $b_\delta = 0.001$)。

表 5 展示了 5 种典型误差分布场景下的维护决策评估结果。

表 5　不同误差分布的维护性能对比

Table 5　Comparison of maintenance performance with different error distributions

场景	维护次数	风险成本/万元	维护成本/万元
场景 1	5	142. 22	198. 31
场景 2	7	318. 04	354. 81
场景 3	10	192. 01	596. 87
场景 4	11	290. 97	858. 71
场景 5	6	214. 73	222. 75

表 5 显示,不同误差场景下维护成本存在显著差异。场景 1 表现最优,风险成本和总成本最低。随着误差场景的逐步恶化,场景 2(a_δ 增至 0. 05)使风险成本增加 123. 62%,总成本上升 78. 91%;场景 3($a_\mu = 0.15$)导致风险成本增加 35. 01%,总成本提升 201%;场景 4 的极端工况则造成误差均值和方差的同步恶化,使得维护成本达到最高。对比分析结果,在高精度预测条件下(场景 1 和 2),系统维护频次和总成本指标均显著优于低精度工况(场景 3 和 4),表明提升预测精度能够有效优化维护需求规划并降低全生命周期运营成本。进一步分析情景 5 可以看出,本文构建的维护决策模型通过合理考虑常规工况下的误差分布特征,在维护频率与成本控制之间实现了最优平衡。

5　结　论

针对海上风电机组 RUL 预测过于理想化导致的维护决策风险问题,本文提出了一种融合动态预测误差与多目标优化的智能维护决策方法。基于典型海上风电场运维数据的算例验证,得出的主要结论如下。

(1)本文模型能够有效表征海上环境多源不确定性引起的 RUL 预测波动,实现系统可靠性与经济性的协同优化。与 CM 和 TBM 相比,该方法避免了高昂维修成本与过度维护;与 PDM 和 POM 相比,通过引入动态预测误差和分级维护机制克服了阈值策略的局限,实现了风险与成本的平衡。在 15 a 运行周期内,维护成本降低 66% ~88%,停机成本减少 48% ~92%。本文模型显著提升了海上风电场的整体运营效益,为海上风电场运维管理提供了有效的解决方案。

(2)当采用适中的决策周期时,维护成本较传统方法大幅降低,展现出突出的经济性优势。通过引入自适应维护效应调节机制,在确保系统可靠性的同时实现了成本的有效控制。同时,研究发现合理的风险偏好参数设置可使系统风险与维护成本达到最优平衡状态。该方法对各类运行工况均表现出良好的适应性,在标准运行条件下能够显著提升系统可靠性并降低运维成本,验证了所提方法的有效性和工程适用性。

本文不仅为海上风电机组智能运维提供了新的技术路径,完善了预测性维护的理论体系,也为实际工程应用提供了科学可行的解决方案。后续研究将进一步探讨不同天气环境和海域条件对维护策略的影响机制,结合规模化风电场群的协同优化问题,并探索高效优化算法与数字孪生技术的结合,以提升模型的实时性与工程适用性。

参考文献(References):

[1] 汪敏, 荣腾飞, 李茜, 等. 基于可学习小波自注意力模型的海上风电功率超短期预测[J]. 高电压技术, 2025, 51(3): 1422 - 1433.
Wang Min, Rong Tengfei, Li Qian, et al. Ultra-short term prediction of offshore wind power based on learnable wavelet self-attention model [J]. High Voltage Engineering, 2025, 51(3): 1422 - 1433.

[2] 李杨, 董雪, 杨霄, 等. 海上起重机人员转运事故的 $N-K$ 模型风险耦合分析[J]. 安全与环境学报, 2025, 25(5): 1675 - 1682.
Li Yang, Dong Xue, Yang Xiao, et al. Risk coupling analysis of offshore crane personnel transfer accidents based on the $N-K$ model risk approach[J]. Journal of Safety and Environment, 2025, 25(5): 1675 - 1682.

[3] 魏书荣, 胡徐曾, 符杨, 等. 基于 VAE - ECAAtt - BiLSTM 模型的海上风电机组复合故障预警[J]. 电力自动化设备, 2025, 45(12): 235 - 244.
Wei Shurong, Hu Xuzeng, Fu Yang, et al. Early warning of composite faults in offshore wind turbine based on VAE - ECAAtt - BiLSTM modeling [J]. Electric Power Automation Equipment, 2025, 45(12): 235 - 244.

[4] 常丁懿, 石娟, 瞿丽莉, 等. 智慧风电场应急管理体

系及应用研究：5G 技术赋能[J]. 中国安全科学学报，2022，32(9)：57－67.
Chang Dingyi, Shi Juan, Qu Lili, et al. Smart emergency management system in wind farms and its application: 5G technology empowerment [J]. China Safety Science Journal, 2022, 32(9): 57－67.

[5] 丰力，张莲梅，韦家佳，等. 基于全生命周期经济评估的海上风电发展与思考[J]. 中国电力，2024，57(9)：80－93.
Feng Li, Zhang Lianmei, Wei Jiajia, et al. Development & thinking of offshore wind power based on life cycle economic evaluation[J]. Electric Power, 2024, 57(9): 80－93.

[6] 董文康，吴雨芯，姚琦，等. 基于深度强化学习的海上风电机组状态维护与备件库存联合优化[J]. 太阳能学报，2023，44(12)：190－199.
Dong Wenkang, Wu Yuxin, Yao Qi, et al. Joint optimization of state maintenance and spare parts inventory of offshore wind turbines based on deep reinforcement learning[J]. Acta Energiae Solaris Sinica, 2023, 44(12): 190－199.

[7] 李海燕，李亚平，韩腾飞. 考虑自然退化与冲击的风电机可靠性评估与预防维护策略研究[J]. 工业工程，2023，26(3)：67－74.
Li Haiyan, Li Yaping, Han Tengfei. A reliability assessment and preventive maintenance strategy of wind turbines considering natural degradation and shocks[J]. Industrial Engineering Journal, 2023, 26(3): 67－74.

[8] Cheng Jianda, Liu Yan, Li Wei, et al. Deep reinforcement learning for cost-optimal condition-based maintenance policy of offshore wind turbine components [J]. Ocean Engineering, 2023, 283: 115062.

[9] Luo Jiaxuan, Luo Xiaofang, Ma Xiandong, et al. An integrated condition-based opportunistic maintenance framework for offshore wind farms [J]. Reliability Engineering & System Safety, 2025, 256: 110701.

[10] 黄晟，凌吉莉，魏娟，等. 大规模风电机群服役质量调控方法研究综述[J]. 电工技术学报，2025，40(10)：3274－3300.
Huang Sheng, Ling Jili, Wei Juan, et al. A review of regulation method of service quality of large-scale wind farm [J]. Transactions of China Electrotechnical Society, 2025, 40(10): 3274－3300.

[11] Wang Lubing, Zhu Zhengbo, Zhao Xufeng. Dynamic predictive maintenance strategy for system remaining useful life prediction via deep learning ensemble method [J]. Reliability Engineering & System Safety, 2024, 245: 110012.

[12] Dong Enzhi, Zhan Xianbiao, Yan Hao, et al. A data-driven intelligent predictive maintenance decision framework for mechanical systems integrating transformer and kernel density estimation [J]. Computers & Industrial Engineering, 2025, 201: 110868.

[13] Ma Yikai, Zhang Wenjuan, Branke J. Multi-objective optimisation of multifaceted maintenance strategies for wind farms [J]. Journal of the Operational Research Society, 2023, 74(5): 1362－1377.

[14] Lu Biao, Wang Xin, Cui Weiwei, et al. A predictive opportunistic maintenance policy for a serial-parallel multi-station manufacturing system with heterogeneous components [J]. Reliability Engineering & System Safety, 2025, 256: 110711.

[15] McMorland J, Collu M, McMillan D, et al. Opportunistic maintenance for offshore wind: a review and proposal of future framework [J]. Renewable and Sustainable Energy Reviews, 2023, 184: 113571.

[16] McMorland J, Flannigan C, Carroll J, et al. A review of operations and maintenance modelling with considerations for novel wind turbine concepts [J]. Renewable and Sustainable Energy Reviews, 2022, 165: 112581.

[17] 陈龙，刘璐洁，符杨，等. 计及高风速和低风速影响的海上风电机组两阶段滚动优化维护策略[J]. 智慧电力，2024，52(7)：80－87，95.
Chen Long, Liu Lujie, Fu Yang, et al. Two-stage rolling optimized maintenance strategy for offshore wind turbines considering the influence of high & low wind speed[J]. Smart Power, 2024, 52(7): 80－87, 95.

[18] 张晓红，张剑飞，何于港，等. 基于多状态空间划分的风电机组非完美维修决策[J]. 太阳能学报，2022，43(11)：203－214.
Zhang Xiaohong, Zhang Jianfei, He Yugang, et al. Imperfect maintenance decision of wind turbine based on multi-state space partitioning[J]. Acta Energiae Solaris Sinica, 2022, 43(11): 203－214.

[19] 王金贺，秦亚鹏，陈嘉玉，等. 考虑环境中冲击影响的风电机组双动态阈值维修决策[J]. 太阳能学报，2025，46(5)：602－611.
Wang Jinhe, Qin Yapeng, Chen Jiayu, et al. Research on maintenance decision of wind turbine with dual dynamic threshold considering shock from environment [J]. Acta Energiae Solaris Sinica, 2025, 46(5): 602－611.

[20] 宋明阳, 瞿晟珉, 秦少茜, 等. 基于故障风险水平的海上风电场机会维护策略[J]. 电力工程技术, 2023, 42(6): 117 - 129.
Song Mingyang, Qu Shengmin, Qin Shaoqian, et al. Offshore wind farm opportunity maintenance strategy based on failure risk level [J]. Electric Power Engineering Technology, 2023, 42(6): 117 - 129.

[21] 修炳杰. 融合多源运维数据的风电机组状态评价与维护策略研究[D]. 吉林: 东北电力大学, 2023.
Xiu Bingjie. Research on wind turbine condition evaluation and maintenance strategy based on multi-source operational and maintenance data [D]. Jilin: Northeast Electric Power University, 2023.

[22] 黄玲玲, 马永杰, 应飞祥, 等. 基于剩余寿命预测信息的风电场动态成组维护策略研究[J]. 电力系统保护与控制, 2024, 52(16): 178 - 187.
Huang Lingling, Ma Yongjie, Ying Feixiang, et al. Dynamic group maintenance strategy for a wind farm based on residual life prediction information[J]. Power System Protection and Control, 2024, 52(16): 178 - 187.

[23] 李梦草, 张正新, 司小胜, 等. 基于非线性 Wiener 过程的多模式随机退化设备剩余使用寿命预测方法[J]. 机械强度, 2025, 47(9): 221 - 232.
Li Mengcao, Zhang Zhengxin, Si Xiaosheng, et al. Nonlinear-Wiener-process-based remaining useful life prediction method for stochastic deteriorating devices with multiple modes [J]. Journal of Mechanical Strength, 2025, 47(9): 221 - 232.

[24] Zhang Jianxun, Zhang Jialing, Zhang Zhenxin, et al. Remaining useful life prediction for stochastic degrading devices incorporating quantization [J]. Reliability Engineering & System Safety, 2024, 250: 110223.

[25] 徐自力, 高京京, 覃曼青, 等. 基于混合机器学习模型的两级加载下金属材料的剩余疲劳寿命预测方法[J]. 机械工程学报, 2025, 61(12): 73 - 82.
Xu Zili, Gao Jingjing, Qin Manqing, et al. Hybrid machine learning method for remaining fatigue life prediction of the metallic materials under two-step loading[J]. Journal of Mechanical Engineering, 2025, 61(12): 73 - 82.

[26] Sun Bo, Pan Junlin, Wu Zeyu, et al. A model-free deep learning-based health prognosis methodology with epistemic and aleatoric uncertainties[J]. Expert Systems with Applications, 2025, 284: 127835.

[27] 宋李俊, 刘松林, 辛玉, 等. 基于轴承退化状态评估和改进图注意力双向门控循环单元网络的轴承剩余寿命预测[J]. 中国机械工程, 2025, 36(7): 1562 - 1572.
Song Lijun, Liu Songlin, Xin Yu, et al. Residual life prediction for bearings based on bearing degradation state assessment and IGAT-BiGRU network [J]. China Mechanical Engineering, 2025, 36(7): 1562 - 1572.

[28] Benatia M A, Hafsi M, Ben Ayed S. A continual learning approach for failure prediction under non-stationary conditions: application to condition monitoring data streams[J]. Computers & Industrial Engineering, 2025, 204: 111049.

[29] 范乐贤, 刘淑杰, 张洪潮. 综合多阶段退化和多不确定轴承剩余寿命预测[J]. 现代机械, 2022(6): 33 - 39.
Fan Lexian, Liu Shujie, Zhang Hongchao. Prediction of remaining useful life of bearing based on multistage degradation and multi-variability [J]. Modern Machinery, 2022(6): 33 - 39.

[30] Li Mingxin, Jiang Xiaoli, Carroll J, et al. A closed-loop maintenance strategy for offshore wind farms: incorporating dynamic wind farm states and uncertainty-awareness in decision-making [J]. Renewable and Sustainable Energy Reviews, 2023, 184: 113535.

[31] 张召冉, 张楠, 杨明. 基于两阶段模型的应急物资储备库选址优化[J]. 安全与环境学报, 2025, 25(8): 3189 - 3197.
Zhang Zhaoran, Zhang Nan, Yang Ming. Optimizing the site selection of emergency material reserve warehouses using a two-stage model [J]. Journal of Safety and Environment, 2025, 25(8): 3189 - 3197.

[32] Kang Jichuan, Guedes Soares C. An opportunistic maintenance policy for offshore wind farms[J]. Ocean Engineering, 2020, 216: 108075.

[33] Li Mingxin, Jiang Xiaoli, Carroll J, et al. Operation and maintenance management for offshore wind farms integrating inventory control and health information[J]. Renewable Energy, 2024, 231: 120970.

[34] Tao Zijian, Zhu Ronghua, Hu Jiajun, et al. A novel hierarchical failure analysis approach targeting the operation and maintenance of floating offshore wind turbines[J]. Renewable Energy, 2025, 241: 122267.

[35] Li Mingxin, Jiang Xiaoli, Carroll J, et al. A multi-objective maintenance strategy optimization framework for offshore wind farms considering uncertainty[J]. Applied Energy, 2022, 321: 119284.

Optimizing opportunistic maintenance for offshore wind turbines: addressing uncertainty in life prediction

Li Yanan, Zhang Xinsheng, Wu Chunyang, Zhang Zhenlong, Su Jia

(School of Management, Xi'an University of Architecture and Technology, Xi'an 710055, China)

Abstract: This study introduces a multi-strategy collaborative optimization approach to enhance maintenance decision-making in offshore wind turbines amidst uncertainties in lifetime prediction. In contrast to conventional deterministic strategies, the proposed method integrates uncertainty directly into the optimization framework, ensuring a thorough balance between cost and risk considerations. Initially, a dynamic probabilistic modeling scheme is employed to represent the time-varying nature of prediction errors. By developing a residual life prediction error model grounded in time-dependent probability distributions, this approach effectively captures the evolving stochastic characteristics inherent in degradation forecasts. Second, a cumulative maintenance risk quantification model is developed within the Conditional Value-at-Risk (CVaR) framework. This model addresses the asymmetric impacts of prediction errors on maintenance outcomes and offers a comprehensive measure of risk exposure. Monte Carlo sampling is utilized to generate sets of uncertain scenarios, facilitating robust estimation of potential loss distributions. Leveraging these models, a hierarchical maintenance strategy is formulated that integrates corrective, preventive, and opportunistic maintenance into a cohesive framework. To optimize both maintenance costs and operational risks throughout the turbine's life cycle, a multi-objective maintenance optimization model is established. The Nondominated Sorting Genetic Algorithm Ⅱ (NSGA-Ⅱ) is employed to solve this model, facilitating efficient exploration of the Pareto frontier and enabling coordinated optimization of strategy selection and decision thresholds. Case study results confirm the effectiveness of the proposed approach, demonstrating that the optimized strategies significantly reduce maintenance costs while precisely quantifying and mitigating operational risks. Notably, the integration of probabilistic modeling with scenario-based risk evaluation ensures that maintenance policies remain robust against various sources of uncertainty. In conclusion, the proposed method not only enhances the economic efficiency of offshore wind turbine operations and maintenance but also establishes a rational trade-off between cost and risk. These contributions provide a systematic and practical decision-support framework that can be applied to other complex engineering systems facing similar uncertainty-driven challenges.

Key words: safety engineering; offshore wind turbine; lifetime prediction error; opportunistic maintenance; conditional value-at-risk; multi-objective optimization