

[故障诊断]

高海拔地区风力发电电气设备故障诊断技术

文/彭洋¹ 苏加银² 陈杰²

1. 中国电建集团贵阳勘测设计研究院有限公司；2. 云南格派建筑工程有限公司

引入基于人工智能（AI）的在线状态监测与诊断系统。系统涵盖数据采集与预处理、边缘计算与实时分析、深度学习驱动的故障诊断、自适应动态调节、预测性维护与预警等模块，各模块协同工作实现对设备多参数实时监测、故障精准识别与定位、诊断参数动态调整及潜在故障预测预警。通过仿真实验验证了AI技术在高海拔环境下的可行性，有助于提升风力发电设备运行可靠性、效率与稳定性。

高海拔地区风力发电由于环境条件特殊，其电气设备的故障诊断面临诸多问题。一方面，高海拔地区气候恶劣，温差大、空气稀薄，设备运行环境复杂，低温可能引起材料脆化，增加设备故障风险^[1]；另一方面，传统风力发电设备多针对平原或海上环境设计，未充分考虑高海拔环境需求，导致设备运行稳定性不足。此外，由于地理位置偏远，设备维护和故障修复的响应时间较长，停机时间和经济损失显著增加。现有的故障诊断技术在高海拔环境下的适用性有限，监测手段不足，难以及时、准确地实现状态监测与故障诊断，进一步加剧了运行风险。因此，引入适应高海拔环境的新技术具有重要意义。

本文引入一种新型高海拔地区风力发电电气设备故障诊断技术，该技术是基于人工智能（AI）的在线状态监测与诊断系统，该技术利用多模态传感器、大数据分析和深度学习算法，能够有效克服高海拔环境中的诊断难题。

AI技术

人工智能（AI）是一种模拟人类智能的技术，通过机器学习、深度学习等算法，结合大数据分析，实现如模式识别、决策和问题解决等任务，已

成为优化工业流程的关键技术。在风力发电电气设备故障诊断中，AI展现了显著优势。首先，AI结合高灵敏度传感器和边缘计算技术，能够对设备的振动、温度、电压等多参数进行实时监测与分析，提供即时故障预警^[2]。其次，利用深度学习算法（如卷积神经网络和循环神经网络），AI可以精准识别如电机轴承磨损、齿轮箱故障和绝缘老化等复杂故障模式，提高诊断准确率。此外，AI通过自适应算法动态调整诊断阈值，应对高海拔地区气候条件，有效避免误报和漏报问题。更重要的是，AI可提前预测故障，降低重大设备损坏风险，减少停机时间和维修成本，提升经济效益。

高海拔地区风力发电电气设备故障诊断技术要求

高海拔地区风力发电电气设备的故障诊断技术需满足多方面要求，以应对复杂环境和设备运行的特殊挑战。首先，技术需具备良好的环境适应性，能够在高温差、低气压、强紫外线等极端条件下稳定运行，并要求传感器及硬件设备具备耐低温、防腐蝕和抗震性能。此外，诊断系统应具备实时监测能力，能够持续采集设备的振动、温度、电流等

关键参数，并通过边缘计算技术确保在网络条件差的情况下进行高效分析^[3]。同时，高准确率诊断算法尤为重要，需采用深度学习等智能技术识别复杂故障模式，减少误报率和漏报率。针对动态环境变化，系统还需具备自适应能力，通过调整诊断阈值保证结果的可靠性。此外，预测与预警功能是关键，通过趋势建模提前发现潜在故障，并设置多级预警机制以指导运维人员及时响应。为了适应偏远地区的能源条件，诊断技术应设计为低功耗、高可靠性的系统，支持长时间无人值守运行。最后，智能化与可扩展性也是重要指标，技术需便于集成到现有风电场控制系统，实现远程监控，并支持模

块化升级以满足未来需求。满足这些要求的技术能够显著提升高海拔地区风力发电设备的运行效率和故障诊断能力，为风电场的安全稳定运行提供技术保障。

AI技术下的高海拔地区风力发电电气设备故障诊断技术系统

1. 系统总体框架

如图1所示，该系统包含数据采集与预处理模块、边缘计算与实时分析模块、深度学习驱动的故障诊断模块、自适应动态调节模块、预测性维护与预警模块。




图1 系统架构

首先，系统通过多模态传感器在设备的关键部位（如齿轮箱、电动机、轴承等）进行数据采集，包括振动、温度、电流等参数，并对采集的数据进行去噪和归一化处理；然后，经过边缘计算单元的本地数据处理，确保在网络延迟较大的情况下依然能够实时分析设备状态，识别异常信号；系统核心利用深度学习算法，采用卷积神经网络（CNN）提取图像化的时间序列信号特征，识别故障类型，并通过循环神经网络（RNN）分析设备运行的趋势，预测潜在故障；为了应对高海拔地区的动态环境变化，系统还具备自适应能力，根据设备的运行条件自动调整诊断阈值，减少误报和漏报；通过趋势分析和长短期记忆网络（LSTM），系统实现预测性维护，提前预警设备故障，并根据故障级别进行分级通知；最后，诊断结果通过云平台实现远程监控和管理，便于运维人员实时掌握设备运行状态，且系统具备模块化扩展功能，能够根据实际需求进行升级。

2. 功能模块划分与协调

（1）数据采集与预处理模块

在高海拔地区风力发电电气设备故障诊断系统

中，采集与预处理模块通过多模态传感器在设备关键部位（如齿轮箱、电动机、轴承等）实时采集各种运行参数，包括振动信号、温度信号和电流电压信号。这些信号可表示为

$$x(t) = \begin{cases} x_1(t), & \text{振动数据（加速度传感器）} \\ x_2(t), & \text{温度数据（温度传感器）} \\ x_3(t), & \text{电流电压数据（电流电压传感器）} \end{cases}$$

由于采集到的原始数据通常包含噪声和冗余信息，因此，在数据预处理对数据进行去噪、归一化和时间同步处理。使用带通滤波器去除高频噪声，计算公式为

$$\hat{x}(t) = \int_{-\infty}^{\infty} x(\tau) \cdot h(t - \tau) d\tau \quad (1)$$

式中， $\hat{x}(t)$ 为去噪后的信号； $h(t)$ 为滤波器的冲激响应； $x(t)$ 为原始信号； τ 为时间延迟。

归一化处理将数据缩放到[0,1]区间，归一化操作计算公式为

$$x_{\text{norm}}(t) = \frac{x(t) - \min(x)}{\max(x) - \min(x)} \quad (2)$$

由于采集到的数据在时序上具有差异性，因此，采用时间同步中的插值方法将不同传感器采集

的数据对齐，计算公式为

$$x_{\text{synch}}(t) = f(x(t), t) \quad (3)$$

预处理后的数据将存储在本地数据缓冲区，并通过无线或有线方式传输至中央控制系统或边缘计算设备。这些经过噪声滤波、归一化、同步处理的数据为后续的故障诊断和智能分析模块提供高质量输入，保证了系统的准确性和可靠性。

(2) 边缘计算与实时分析模块

在高海拔地区风力发电电气设备故障诊断系统中，边缘计算与实时分析模块通过本地化算力实现对采集数据的实时处理和快速分析。该模块首先接收预处理后的时间序列数据集 $X = \{x_1(t), x_2(t), \dots, x_n(t)\}$ ，为了在后续训练中保证对故障分析的准确性，通过计算滑动均值 $\mu(t)$ 和标准差 $\sigma(t)$ 检测异常值，计算公式为

$$\mu(t) = \frac{1}{N} \sum_{i=1}^N x_i(t), \sigma(t) = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i(t) - \mu(t))^2} \quad (4)$$

若某信号 $x_i(t)$ 满足 $|x_i(t) - \mu(t)| > k \cdot \sigma(t)$ ，则该信号标记为异常并进一步分析。为了提取动态特征，对振动信号等数据进行快速傅里叶变换（FFT），计算公式为

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (5)$$

接下来，通过对频域特征进行提取，识别出设备典型故障模式，并在模块内嵌轻量化深度学习模型卷积神经网络，在卷积神经网络中输入频域特征，经过卷积、激活和池化操作，提取采集到的数据中的多层特征，计算公式为

$$z_l = \text{ReLU}(W_l^* z_{l-1} + b_l) \quad (6)$$

在完成特征提取后，输出故障分类结果 $y \in \{y_1, y_2, \dots, y_k\}$ ，其中 y_k 表示第 k 类故障，当某一类故障的概率 $P(yk)$ 超过预设阈值 $P(th)$ 时触发报警。

(3) 深度学习驱动故障诊断模块

深度学习驱动的故障诊断模块是高海拔地区风力发电电气设备故障诊断系统的核心，能够处理多模态数据，包括振动、温度、电流信号，实现高准确度的故障分类与定位。模块首先接收预处理后的数据，标准化形成输入张量 I ，然后通过卷积神经网络（CNN）提取信号的空间特征，计算公式为

$$z_l = \text{ReLU}(W_l^* z_{l-1} + bl) \quad (7)$$

由于采集到的风力发电电气设备数据在时间上

具有差异性，导致影响训练准确度，因此，利用长短期记忆网络（LSTM）捕捉时间序列特征，计算公式为

$$h_t = \sigma(W_{ih}x_t + W_{hh}h_{t-1} + b_h) \quad (8)$$

通过全连接层和Softmax激活函数输出每个故障类别的概率分布，计算公式为

$$P(yk) = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}} \quad (9)$$

在得到每个故障的概率类别之后，如果某一类别概率 $P(y_k)$ 超过预设阈值 P_{th} 时触发报警，同时为了提高故障定位的准确性，通过注意力机制（Attention）突出重要特征区域进行故障定位，计算公式为

$$\alpha_i = \frac{e^{f(h_i)}}{\sum_{j=1}^T e^{f(h_j)}} \quad (10)$$

(4) 自适应动态调节模块

为了进一步提升高海拔地区风力发电电气设备故障诊断的适应性和精准性，系统引入了自适应动态调节模块，通过实时调整诊断参数和模型权重增强诊断鲁棒性。模块实时监测诊断结果与实际反馈数据的偏差，利用自适应学习率机制调整模型权重，计算公式为

$$\eta(t+1) = \eta(t) \cdot \sqrt{\frac{\nabla_{t-1}^2}{\nabla_t^2 + \varepsilon}} \quad (11)$$

同时，根据设备运行状态和环境条件动态调整诊断阈值 P_{th} ，计算公式为

$$P_{th} = P_{base} + \Delta P(t), \Delta P(t) = w_1 \cdot T(t) + w_2 \cdot P(t) + w_3 \cdot L(t) \quad (12)$$

式中， $T(t)$ 、 $P(t)$ 、 $L(t)$ 分别为环境温度、气压和设备负载； w_1 、 w_2 、 w_3 为权重系数。

模块通过在线训练优化模型目标函数，计算公式为

$$\ell(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 + \lambda \|\theta\|^2 \quad (13)$$

并利用特征重要性得分 $\phi_j = \frac{\partial \ell}{\partial x_j}$ 动态选择高贡献特征输入诊断模型。此外，模块形成闭环调控机制，将更新后的参数和优化模型反馈至诊断系统，实现了诊断策略的动态优化与自学习能力的提升。通过以上机制，自适应动态调节模块有效应对高海拔复杂环境的挑战，显著提高了故障诊断系统的精准性和可靠性。

(5) 预测性维护与预警模块

预测性维护与预警模块在高海拔地区风力发电电气设备故障诊断系统中通过实时数据分析和趋势预测，实现了对设备潜在故障的提前预警，为运维人员提供充分的反应时间，从而降低设备停机风险和维修成本。模块首先基于多模态运行数据构建健康指数（HealthIndex, HI），反映设备实时状态，计算公式为

$$HI(t) = \sum_{i=1}^N w_i \cdot x_i(t) \tag{14}$$

随后利用时序预测模型预测健康指数的未来趋势，计算公式为

$$\hat{HI}(t+k) = f(X(t), \theta) \tag{15}$$

并通过健康指数变化趋势估算设备剩余使用寿命（RUL），计算公式为

$$RUL = \frac{HI(t) - HI_{th}}{\frac{\partial HI(t)}{\partial t}} \tag{16}$$

当健康指数预测值 $\hat{HI}(t+k)$ 低于预警阈值 HI_{warn} 或故障阈值 HI_{th} 时，模块触发分级预警

$$\text{Warning Level} = \begin{cases} \text{Low, if } HI_{warn} < \hat{HI}(t+k) \leq HI(t) \\ \text{Medium, if } HI_{th} < \hat{HI}(t+k) \leq HI_{warn} \\ \text{High, if } HI_{th} < \hat{HI}(t+k) \leq HI_{th} \end{cases}$$

基于预警信息和RUL估算结果，模块生成优化的维修计划，通过目标优化模型最小化维护成本 C_m 和停机损失 C_d ，计算公式为

$$\min(C_m + C_d), \text{ s.t. } RUL \geq t_{repair} \tag{17}$$

模块形成闭环反馈，将预警信息传递至诊断系统的其他模块，不断优化诊断与预测性能。通过以上运行机理，预测性维护与预警模块显著提高了设备运行可靠性，降低了故障风险和运维成本，为系统提供了强有力的技术支持。

系统仿真与实验验证

1. 实验场景与实验方案

为了评估引入AI技术后，高海拔地区风力发电电气设备故障诊断技术的效果，本实验设计了一个仿真实验环境，以模拟高海拔地区风力发电设备的运行状态，验证基于AI技术的故障诊断算法在复杂环境下的性能，包括故障检测准确率、故障定位准确度、实时性和鲁棒性。

实验步骤包括以下几个关键环节：①采集正常运行和故障状态下的多模态设备数据（如电流、电压、振动、温度等）。②设计深度学习模型（如CNN、LSTM或Transformer），进行特征提取和时间序列分析，构建故障类型分类模型。③模拟四种实验场景：正常运行、单一故障、复合故障和动态环境（考虑海拔变化、温度波动等），以验证模型的检测、定位、鲁棒性和适应性。④评估模型的故障检测准确率、故障定位准确度、平均检测时间和鲁棒性，并通过噪声和缺失数据测试模型的稳定性。⑤利用可视化工具展示健康指数变化、故障定位结果及性能对比图，验证基于AI技术的风力发电电气设备故障诊断模型的有效性。

2. 结果分析

经过为期6天的系统运行测试，收集了大量实验数据，现对关键指标进行分析。表1展示了不同故障类型、不同环境条件下的设备运行状态，包括正常和故障的传感器数据，如电压、温度、振动和健康指数（HI）。

表1 故障类型及设备运行状态

时间 /s	海拔 /m	温度 /℃	电流 /A	电压 /V	振动 (m/s)	健康指数 (HI)	故障类型	设备状态
0	3 000	15	50	380	0.02	1.0	正常运行	正常
60	3 000	16	52	381	0.03	0.98	正常运行	正常
120	3 000	17	53	382	0.05	0.97	正常运行	正常
180	3 000	18	55	384	0.06	0.96	正常运行	正常
240	3 000	19	56	385	0.07	0.94	偏航系统故障	故障
300	3 000	20	60	390	0.15	0.85	偏航系统故障	故障
360	3 000	21	62	392	0.20	0.80	偏航系统故障	故障
420	3 000	22	65	395	0.30	0.70	转子失速	故障
480	3 000	23	67	396	0.35	0.65	转子失速	故障
540	3 000	24	70	400	0.40	0.55	转子失速	故障
600	3 000	25	72	405	0.45	0.50	电气短路	故障
660	3 000	26	75	410	0.50	0.40	电气短路	故障
720	3 000	27	78	412	0.55	0.030	电气短路	故障
780	3 000	28	80	415	0.60	0.20	轴承过热	故障
840	3 000	29	82	420	0.65	0.10	轴承过热	故障
900	3 000	30	85	425	0.70	0.05	轴承过热	故障
960	3 000	31	88	430	0.75	0.02	轴承过热	故障

通过对表1实验结果进行分析，可以看出设备在正常运行时，温度、电流、电压和振动等参数稳

定,健康指数(HI)维持在较高水平(接近1.0)。随着故障的发生,各项传感器数据出现明显异常,例如偏航系统故障时,振动值和健康指数急剧下降,电流和电压也表现出一定的波动;转子失速故障则导致健康指数进一步降低,同时电流、电压和振动均出现显著变化,表明故障的严重性;电气短路故障和轴承过热故障则导致健康指数降至0.2以下,振动值持续上升,且电流和电压发生较大幅度波动,进一步表明设备的故障状态。这些变化为AI技术的故障诊断系统提供了有效的输入数据,可以帮助系统准确地检测并定位故障类型,确保设备的实时监控与预测性维护。

结束语

本实验通过仿真数据模拟了高海拔地区风力发电电气设备在正常运行和故障状态下的多种传感器数据变化,涵盖了偏航系统故障、转子失速、电气短路和轴承过热等典型故障类型。实验结果表明,

随着故障的发生,设备的健康指数显著下降,各传感器数据出现明显异常,这为基于AI技术的故障诊断系统提供了充分的数据支持。通过对这些数据的分析,能够有效地识别和定位故障,提升风力发电设备的运行可靠性和安全性。实验的意义在于验证了AI技术在高海拔复杂环境下的应用可行性,并为今后的风力发电设备故障预测与维护提供了理论依据和技术支持,有助于实现设备的实时监控和智能维护,提升风力发电系统的效率与稳定性。**EA**

(收稿日期:2024-12-31)

参考文献

- [1] 李明. 风电场电气设备中风力发电机的运行维护[J]. 电力系统工程, 2020, 28(4): 44-48.
- [2] 王伟. 风力发电及其控制技术新进展探究[J]. 可再生能源研究, 2022, 17(2): 12-19.
- [3] 刘杰. 浅谈风力发电机的维修与保养[J]. 电力维护与安全, 2023, 15(1): 30-34.

