风电光伏场站关键设备故障诊断技术研究

张 敏

（大唐丘北风电有限责任公司，云南 文山 663200）

摘 要 随着风电、光伏在能源结构中的占比持续攀升，其场站关键设备的高效运维与精准诊断已成为保障电网安全与经济运行的核心挑战。本文针对新能源场站监测数据多源异构、运行工况复杂多变、故障样本稀缺等实际难题，开展智能故障诊断技术研究。系统分析关键设备故障机理与多源数据特征，研究基于注意力机制的多源数据融合与健康指标构建方法，创新提出变工况自适应学习与小样本迁移诊断模型，并增强模型可解释性，最终构建场站级边云协同监测与动态预警体系，以期为相关人员提供参考。

关键词 风电；光伏；故障诊断；多源数据融合；深度学习

中图分类号：TM61；TH17 **文献标志码**：A DOI：10.3969/j.issn.2097-3365.2026.30.036

0 引言

在“双碳”目标的持续推动下，我国风电、光伏产业已实现规模化、高质量的跨越式发展。但是，新能源场站大多布局在戈壁、山地、沿海等极端环境区域，核心发电设备长期面临恶劣自然环境的考验，设备非计划停机故障率逐年攀升，运维成本不断提高，直接影响场站的实际运营收益[1]。面对这一行业痛点，传统依赖人工巡检、固定阈值告警的运维模式已完全无法适配高密度、大规模新能源场站的运行需求，行业迫切需要构建一套包含多源数据、适合复杂工况、从系统角度出发的智能故障判断体系。

1 风电光伏场站关键设备故障类型与特征分析

1.1 风电机组核心部件典型故障机理

风电机组核心部件故障机理比较复杂。齿轮箱处于动力传递的核心地位，其典型故障包含齿面点蚀、断齿以及轴承磨损等。振动信号里存在特征频率调制和边频带现象。发电机故障大多体现为轴承损坏和绝缘老化，轴承故障会造成特定频率的振动，而绝缘老化则致使局部放电并使得温度不正常上升。叶片出现裂纹、覆冰或者雷击损伤等情况时，会改变自身的气动外形和结构动力学特征，这些特征体现在振动、声音以及功率曲线的异常状况当中。深刻认识这些物理机理是将监测数据转换成故障预判的前提。

1.2 光伏发电单元主要失效模式

光伏发电单元存在多种失效模式，光伏组件常见的失效类型有热斑效应、电位诱导衰减以及隐裂等情况，其中热斑会引发局部高温并致使输出功率缩减，而电位诱导衰减（PID）会造成组件性能逐步下降。逆变器属于关键的电力电子装置，它的IGBT模块会发生疲劳老化现象，直流母线电容的容值也会出现衰减情况，这些都是主要故障表现，其具体体现为输出波形发生畸变、谐波含量增多。汇流箱和接线盒往往会出现连接点松动、烧蚀以及直流电弧故障等状况，从而致使接触电阻变大、绝缘性能减弱。这些失效模式最终都会表现在输出电流－电压特性发生异常变化上。

1.3 多源异构监测数据特征提取与筛选

风电光伏场站装有SCADA、振动、红外、电气等多源异构监测系统，可以从SCADA的时序数据当中获取均值、方差、偏度之类的时域统计特性[2]。解决“维数灾难”需要执行特征筛选，可以依靠滤波器，也可以用像递归特征删除这样的封装方法，并结合分类器的表现来做选择，为后续的融合和判断提供数据依据。

2 多源数据融合与状态表征方法

2.1 异构传感器数据预处理与时间配准

多源数据融合之前要执行严格的预处理步骤，其中涉及数据清洗环节，用以解决缺失值以及那些较为明显的异常点问题，可以利用插值法或者前后均值法来填补空缺之处。数据规范化目的在于把各个特征的尺度归于同一水平，常见的做法是采用最小－最大规范化或者是Z-score标准化方法。而时间配准则属于一项主要难点，因为不同传感器的采样频率存在很大

作者简介：张敏（1996-），女，本科，助理工程师，研究方向：风电场合同管理、结算、采购立项。

差别，针对秒级 SCADA 数据和分钟级振动数据等情况，有必要把高频次的数据执行降采样操作，或者给低频次数据实施插值处理，从而使其达到相同的起始时间点。一般按照诊断分析所必需的最低时间分辨率（每十分钟间隔）来做重采样和对齐工作，这样才能保证同一时段下各类不同模态的数据得以有效相互关联。

2.2 基于深度学习的跨模态特征融合策略

深度学习给多模态数据深度挖掘提供很强的互补信息工具。可以运用依靠特征级融合的深度网络架构，比如用一维卷积神经网络来处理振动时序信号，获取它的局部依赖和频谱特征；再用长短期记忆网络去处理 SCADA 慢变参数序列，找到其中的长期趋势。之后在网络的中间层把不同路径得到的高阶抽象特征做拼接或者加权融合。更为先进的方法是采用注意力机制，让网络自己学会各个模态特征对于特定故障判断任务来说的重要程度权重，实现自适应的特征融合，进而产生更具区分能力的综合特征表现形式。

2.3 设备健康状态退化指标构建

创建连续的健康状态退化指标对于实现预测性守护十分关键。依靠融合之后的深度特征，可以形成健康基线模型。一种常见的做法是训练一个只采用正常状态数据的深度自编码器网络，其重构误差就能够充当健康指标，设备状态离正常越远，重构误差就越大。还有一种方法是利用健康状态评分模型，把融合特征映射成 0 到 100 之间的健康指数，这个指数能够直观表现设备从“健康”过渡到“亚健康”，再到“故障”的连续退化情况，给早期预警和剩余使用寿命预测提供予定量依据，从而做到从二值判断向连续趋势分析的状态评价转变。

3 复杂工况下智能故障诊断模型

3.1 变工况自适应特征学习网络

实际场站中的设备工况起伏很大，这会影响到干扰特征的获取。要想加强模型的鲁棒性，就要形成变工况自适应学习网络，其核心在于学习与工况无关的故障敏感特征。可以利用对抗性学习框架，主干特征获取网络在生成判别性特征时，会加入一个工况判别器网络，通过对抗训练，促使主干网络获取的特征能够“蒙蔽”工况判别器，也就是特征里最好不包含风速、功率之类的工况信息，以此去掉这些干扰因素[3]。最后，模型学到的特征重点体现设备自身良好的状况，这样无论处于何种工况，相同的故障都会表现出类似的特征，从而大幅优化了判断模型的泛化能力。

3.2 小样本条件下故障迁移诊断技术

工业判断当中，严重故障样本稀少属于常见情况。迁移学习是一种有效的应对方案，可以凭借源领域，比如其他风场或者仿真平台，其包含大量历史故障数据，预先训练一个深度判断模型。对于目标领域即特定新场站，它只有少量样本数据，这时采用微调策略，把网络底层用来获取通用特征的层固定住，仅仅依靠少数目标样本去微调上面的分类器，促使模型尽快适应新设备的特点。还可以运用领域自适应方法，最大均值差异损失之类的方式，在特征方面缩小源域和目标域的数据分布差距，实现知识从“数据充足之处”向“数据缺少之地”的有效过渡，从而解决冷启动问题。

3.3 模型可解释性与诊断置信度评估

加强“黑箱”模型的可信度研究十分关键。可以利用类激活映射这样的可视化技术，把模型用于判断故障所依赖的部分，以热力图的形式重新显现到最初的输入数据之上，比如标示出那些引发判断属于“轴承故障”的重要振动频段区域，从而让诊断结论具备可追溯性。而且，给诊断输出添加置信度评定，可通过模型在 softmax 层的输出概率，或者借助贝叶斯神经网络来估算预测的不确定性。对于置信度较低的诊断结果，系统会启动人工复查机制，防止盲目相信模型，进而创建可靠的人机协作诊断闭环，提升该技术在工程实际应用中的认可度和实用性。

4 场站级协同监测与预警体系

4.1 设备间耦合影响与故障传播路径分析

场站内设备并非各自独立运行。风机之间存在尾流效应，风机由于故障停机时，会改变风流场，从而加重下风向风机载荷波动及疲劳程度。在光伏阵列当中，组串内部的组件呈串联状态，单个组件若出现严重故障，很可能造成整串功率急剧缩减。深入剖析此类物理与电气关联十分关键，可以凭借图论来对场站执行拓扑建模，把节点当作设备，把边视作连接或者影响的联系。融合历史故障资料，采用贝叶斯网络或者因果推断手段，计算故障沿着网络流传的可能性及其影响范围，进而为从系统角度找出源头故障并阻止连锁事件发生提供理论支撑。

4.2 基于边云协同的实时诊断架构设计

为实现随时判断并优化资源的目标，就要规划边云协同架构。在边缘位置，安装在风机或者逆变器控制柜里的轻量化判断模型，依靠本地的计算资源，及时剖析关键且采样率高的数据，做到从毫秒到秒级别

的异常识别以及紧急停机保护。在云端，则汇集全场站大量的过往和即时数据，运行复杂的深度学习及退化趋势预测模型，展开从分钟到小时范围的深入分析和健康评价，而且承担模型训练、优化以及统一更新的任务。云和边通过安全通道来同步，云端向下发送新的模型和阈值，边缘端上传特征和中间结果，从而实现计算负载与判断性能的最优平衡。

4.3 多时间尺度动态预警阈值优化

固定警报阈值很难适应设备的动态运行状况，这极易引发误报和漏报现象。要解决这个问题就得形成多时间尺度的动态警报体系，按照不同的响应需求来设定多种警报层级。秒级阈值适合于振动超限、电流突变等亟需应对的故障情况，可以做到快速防护；而分钟/小时级阈值则用来观察温度逐渐上升、功率出现异常等逐步显现出来的不足之处。这个阈值会遵照设备以往的健康基线即时做出调整，比如利用指数加权移动平均再配合3σ规则来做动态计算；至于天/周级阈值重点在于留意健康指标长时间以来的恶化态势，从而用于预见性的保养工作[4]。这种动态阈值方法不断学习设备正常运行模式，可以有效过滤随机波动和环境噪声，自动适配异常状态与正常波动，大幅提升警报的精准度和可靠性，减轻了运维人员无效巡视的负担。

5 系统验证与工程应用评估

5.1 典型风电场与光伏电站案例验证

为验证所提出的技术体系，选取装机容量为200 MW的典型风电场与100 MW的光伏电站作为案例。风电场采用一年期的SCADA数据和部分关键机组的振动数据，光伏电站则采用逆变器运行数据和Ⅳ扫描数据。把历史工单和报警记录当作故障标签。在实验设置方面，按照时间把正常数据和各类故障数据划分成训练集和测试集，而且利用不同风速和辐照度范围来验证变工况性能。比较的基线模型包含支持向量机、随机森林这些传统方法，还有依靠单个数据源的深度学习模型，以此全方位评估所提出融合和自适应方法的优势。

5.2 诊断时效性与准确率对比分析

在风电机组齿轮箱故障诊断方面，该模型整体准确率达98.7%，比仅依靠单一SCADA数据的诊断方法高5.2%。处于变工况情况下时，该模型针对未见过的工况具备较强的泛化能力，其准确率比未采用对抗性学习方法时高出12.5%。在光伏逆变器IGBT早期故障警报当中，系统实现了平均可提前7天发出故障警报的能力，漏报率小于2%。边云协同架构中的即时性能评定表明，边缘端对于紧急故障判断的延误小于500毫秒，云端执行深度分析的时间间隔为10分钟，如此一来就满足了即时异常检测以及精确状态评价这两个方面的需求。通过混淆矩阵、ROC曲线等可视化分析显示，模型针对各类故障均维持着较好的识别能力和泛化性能。

5.3 运维策略优化与经济效益评价

技术的应用促使运维模式从事后维修朝着预测性维护方向转变。依靠健康状态退化指标，可以制订不同的巡视与维修计划，针对健康指数下滑的部件展开重点巡视，优化备品备件库存。经济效益评定表明，在案例场站当中，大概能够削减非计划停机时间约为20%，增长年发电量超过1.5%，规避重大恶性事故之后便免去了高额维护成本[5]。早期警报和精确判断减少了日常巡视所需的人力，初步估计投资回报期为2年至3年，这就表明智能故障判断技术具备突出的经济效益及其应用推广价值。

6 结束语

通过构建“机理－模型－系统”的风电光伏场站智能故障判断技术体系，多源数据融合和深度学习特征获取，实现了对设备状态的精确感知。改进设计的对抗自适应网络和迁移判断模型明显提升了模型在变工况、小样本情况下的判断能力。边云协作框架和动态警报机制实现了从部件到场站的多层次状态评价。验证结果表明，本文所提出的方法切实加强了故障判断的准确率和早期警报能力，但在应对极端数据缺少状况时的适应性仍需要进一步探究。未来，可将物理机理和深度学习结合起来，探寻同数字孪生平台深入融合的办法，从而实现更具可解释性、适应性更强的智能运维。

参考文献：

[1] 李晓飞.光伏风电系统的实时监控与故障诊断技术[J].科技与创新,2025(22):121-124.
[2] 张家榕.风电光伏场站设备运维中的风险预控技术研究[J].电力设备管理,2025(07):74-76.
[3] 曹瑞峰,刘子华,袁婷,等.基于改进SVM的新能源电站故障诊断方法[J].浙江电力,2023,42(11):11-20.
[4] 王嘉媛,李洋,李媛,等.关于风电、光伏发电与水力发电结合的研究[J].中国设备工程,2023(10):263-265.
[5] 谢望.基于电流特征的光伏和风电变流器开关管开路故障诊断研究[D].合肥:合肥工业大学,2021.