

基于深度学习的电气设备状态监测与故障预测研究

杨文杰

康弘集团四川济生堂药业有限公司 四川彭州 611930

摘要：基于深度学习的电气设备状态监测与故障预测以数据与模型的双轮驱动为主线，把多源信号转化为可度量的健康表征，并在时序演化中识别潜在退化与失效风险。本文构建面向工程落地的理论与方法框架，从对象建模、数据治理、模型架构、在线推断与闭环迭代等方面展开，提出以标准词典与统一编码为底座的全链路方案，强调少样本与弱标注条件下的自监督与迁移策略，以及边云协同与不确定性控制在现场环境中的关键作用。目标是在安全边界内提升告警准确性与预测时效，使监测系统从被动记录走向主动预防。

关键词：深度学习；状态监测；故障预测；自监督学习；边云协同

引言

电气设备在复杂应力与多工况叠加下运行，表现出非线性、时变与耦合的特征，传统基于规则与浅层特征的方法难以稳定覆盖隐性退化。深度学习具备强表征与端到端建模能力，能够在多模态数据中提取与健康关联的结构性线索。然而工程现场存在标注稀缺、数据质量不稳、工况漂移与算力受限等约束，若缺少数据治理与模型约束，算法的效果难以迁移。为此需要在理论与技术两端同时下沉，构建以对象模型、数据标准与评估口径为支点的整体方案，并通过滚动验证与闭环改进把算法与场景长期耦合，形成可解释、可回滚、可审计的运行机制。深度模型并非单点突破的魔法，更像结构化工程，需要以标准化与流程化为骨架，以数据质量与算力配置为筋膜，以解释与安全边界为护栏。只有把对象模型、样本构建、模型训练与上线运维放在同一链条上连续优化，系统才会在长期运行中获得可靠与经济的平衡。本文围绕这一思路展开，力求给出从原理到工程的连贯叙述。

1 理论基础与问题刻画

1.1 对象与信号特征空间建模

状态监测的对象由设备、部件与测点三层构成，需要在统一词典下建立从物理结构到数据通道的对应关系，使任何一条记录都能追溯到位置与功能。信号形态包含电参量、振动与温度等通道，不同通道在时间与频域呈现互补信息，表征空间应同时刻画瞬时轮廓与长期趋势^[1]。为降低维度与噪声干扰，引入分层表征思路，底层提取局部纹理与边缘变化，中层聚合子空间模式，高层对齐健康状态与退化阶段。

对象模型内嵌工况与环境元数据，用以解释分布漂移与域间差异，并为后续的对比学习与条件建模提供先验。健康状态并非固定标签，而是沿时间轴缓慢迁移，模型使用滑动窗口与记忆单元捕捉跨尺度依赖，通过多分辨聚合让短期波动与长期演化在同一坐标下被理解。对复杂拓扑的成套设备，采用图结构表达部件关系与能量传递路径，在图上传播健康信号，构建面向结构的故障敏感子空间，即便局部观测不足也能保持稳定判别力。为增强可迁移性，进一步引入对齐机制，将不同设备与不同工区的表征投射到共享子空间，通过域判别与对比约束减少外部条件差异带来的影响。最后在对象层设置从部件到系统的汇聚规则，把部件级风险按重要度与冗余度进行加权整合，生成系统级风险曲线与优先级清单，使维护计划与资源分配具备清晰的量化依据。对象与信号还需要统一参考基线，以标定与校验环节消除通道漂移。通过定期插入已知模式的校准片段，校验采样链路与传感器响应，把漂移量以参数形式回写模型，使长期趋势与短期变化可分离。对现场不可避免的缺失，以邻域传播与结构约束进行插补，插补结果仅用于特征计算而不进入告警决策，避免误导处置。

1.2 任务拆分与评价体系

故障相关任务可拆为状态识别、异常检测、根因定位与寿命预测四类，彼此在数据需求与时效要求上存在差异。状态识别依托已知标签，强调稳健与可解释，适合用于日常巡检与批量筛查。异常检测面向未知模式，利用重构误差与概率密度稀疏性暴露异常行为，适合早期预警^[2]。根因定位

关注因果线索与部件关联，需要把结构先验纳入模型。寿命预测关注剩余可用时间与退化速率，需要在长期趋势与短期冲击之间建立折中。评价体系覆盖准确性、时效性与稳定性三维，既衡量单次判别的正确，也衡量时间维度的一致表现，并以代价函数体现误报与漏报对现场的不同影响。为保证可迁移性，加入跨工况与跨设备的泛化评估，采用分层抽样与时段留出检验外推能力。对在线场景设置时延与算力预算，把资源占用纳入指标，以免离线优秀而上线失效。还应设置闭环指标，把告警到处置再到恢复的全过程可视化，衡量从发现到行动的总耗时与成效。为提升长期稳定，建立基于差异阈值的滚动校核，周期性回顾阈值命中率与处置成功率，并将经验条目化沉淀到策略库中。在标签体系上采用分层结构，区分症状、部位与根因三类信息，既满足快速判别的需要，也为后续检修留下可操作线索。对阈值与代价曲线建立可编辑模板，现场人员能够根据季节与负荷水平调节容忍区间。对不同设备与不同寿命阶段设置基线档案，用相对偏离而非绝对数值作为参考，减少个体差异造成的误报。在评审流程中引入专家打分与一致性仲裁，把经验系统化地沉淀到评价口径之中。在报表层设置可复用模板，把核心指标与阈值曲线以同一版式展示，方便跨项目对比与长周期追踪。对争议样本保留多方意见与证据路径，在后续回放中给出裁决与原因，避免经验只停留在口头传承。

2 数据治理与样本构建

2.1 采集标准与弱标注策略

数据治理以采样频率、时间基准与命名口径为核心，采集前明确量纲与精度，采集后执行对齐与去噪。对多源通道进行时钟校正，保证跨设备与跨工区的时间一致，使事件能够在全局回放^[3]。现场标注稀缺时，采用弱标注与半监督路径，利用巡检记录与检修工单提供粗粒度时间段，再在窗口内通过变化点检测与重构差异细化边界。引入自监督任务，如遮挡还原与时域顺序判别，使模型在无标签条件下学习结构特征。对少量标准样本设置高质量校核与复核流程，以样本库驱动迁移与微调。为对抗类别不平衡，采用难例采样与代价敏感训练，避免多数类主导。为提升多工况覆盖，按温度、负荷与开停节奏组织样本，确保各类场景得到代表。数据增强在时域与频域双向展开，加入幅值扰动与节奏拉伸等变换，同时保持与物理规律的一致，防止无意义扰动破坏因果结构。对于隐私受限的区域，采用合成样本与联邦协同的

方式共享表征而非原始数据，在不泄露细节的前提下获得广域统计。最后以质量看板跟踪缺失、噪声与漂移等问题的占比，针对性安排补采、复测与再标注计划，使数据资产持续健康。元数据管理覆盖设备版本、固件版本与校准日期，任何一次变更都形成可追溯记录。数据出域遵循授权与脱敏原则，平台只向有权限的角色展示必要细节。对长期存储设置冷热分层与自动归档，既保证回放能力也控制成本。样本建设强调滚动更新，新旧样本按时间切片分配到训练与验证，防止信息泄露。时序切片的边界与采样间隔保持一致，漂移阈值与异常模式以条目形式维护，随版本更新而同步下发，使数据与规则长期对齐。对于跨平台对接，采用映射表与单点校验，先在沙箱环境回放，再放入小范围试行，稳定后再扩大覆盖。

2.2 模型架构与训练机制

模型设计遵循分层与可插拔原则，底层采用卷积与时间混合结构提取局部与全局特征，中层引入注意力聚合跨通道与跨时间的依赖，高层融合结构先验与任务约束完成判别与回归。对多测点的耦合可引入图卷积或消息传播，在拓扑上传播状态信息，提升局部缺测时的鲁棒性^[4]。自监督阶段构建对比学习与掩码重建任务，使模型获得迁移友好的基础表征。监督阶段采用多任务联合，把状态识别、异常评分与寿命回归放入同一网络并共享中间层，利用参数正则与不确定性权重平衡损失。训练过程中设置数据漂移监控与早停策略，防止过拟合与概念偏移。为提升可部署性，结合蒸馏与低秩分解压缩模型，并用量化与裁剪适配边缘算力。对长序列采用分段滑窗与记忆单元组合，在有限资源条件下维持长距离依赖。对难以直接建模的退化轨迹，引入隐变量过程与分段趋势，使模型既能拟合平稳衰减，也能表达突发冲击后的恢复。为确保稳定上线，还需在训练后进行压力测试与鲁棒评估，使用对抗扰动与传感漂移回放检验容忍度，并据此设定安全缓冲区与备用流程。参数选择遵循可解释与可迁移的优先级，搜索空间以物理可接受范围为边界，避免逐分逼近带来的偶然最优。训练完成后进行温度标定与阈值校准，使概率输出与实际命中更一致。对多站点部署构建统一的模型仓库与版本门禁，每次发布附带差异报告与回退脚本，确保故障时能够快速恢复。上线阶段配合金丝雀策略与灰度窗口，先在少量对象上验证收益与风险，再小步放大覆盖，降低切换风险。

3 在线监测与故障预测

3.1 边云协同与实时推断

在线监测需要在边缘与云端之间形成分工。边缘侧承担快速筛查与就地联动，使用轻量模型与阈值规则完成首轮判别，在异常时触发加密片段上送。云端侧承担精细诊断与趋势外推，基于更长窗口与更全信息给出综合结论。两侧通过能力宣告与心跳保持一致，当网络受限时降级到本地模式，待连接恢复后回放补齐。为控制时延，引入流式推断与增量更新，在每个采样周期只处理新增片段，并复用历史状态。对同一对象设置多通道一致性校核，当单通道出现异常而其他通道稳定时推迟判断，降低误报。对批量设备采用分层看板，按风险等级与老化速度排序，现场人员可依据清单安排巡检节奏。跨区域协同时传送摘要统计而非原始波形，既保护敏感信息又保留调度依据。为使预测具有行动价值，还需把建议动作与预期收益一并输出，对应减载、检修或观察三类响应，结合资源占用与安全边界生成可执行步骤，并在闭环中记录反馈用以更新策略与权重。为减轻干扰，设置告警聚合与去重，把短时重复提示归并为单一事件，并叠加趋势强度与影响范围，避免提示泛滥。对关键岗位配置确认环节，允许人工插入先验或延时观察，把人机各自优势结合起来。当预测与实际处置结果不一致时，系统自动创建复盘条目，收集反证并更新样本库，形成自我修正的闭环。系统与维护排班同步，自动避开高风险时段与关键生产窗口，建议在预留时间内完成局部停机或切换。对需要跨班组协同的处置动作，平台生成指派单与交接卡，明确前置条件与责任边界，减少沟通成本。当现场存在并行作业与交叉影响时，策略引擎自动识别冲突，把高风险动作顺延到更安全的窗口，并在看板上给出替代路径。对需要持续观察的对象，系统生成观测计划与复查时间点，避免短时波动触发过度维护。

3.2 不确定性表达与可解释机制

深度模型在非平稳环境中存在多源不确定性，若缺乏量化与展示，将难以被现场采纳。可通过分布输出与集成估计获得区间与置信，区间宽时采取保守策略，区间窄时允许更激进的调度。对寿命预测输出剩余时间的分布而非单点，使计划能够按风险容忍度分层安排。可解释性通过两条路径实现，一条面向信号空间，给出贡献区段与频带权重，用热图标注关键片段，辅助人工复核。另一条面向结构空间，沿图结构回溯到可疑部件与连接，形成从症状到部位的指引，支

持备件准备与检修窗口安排。解释不以修辞为目标，而以可执行为目的，任何解释都应能转化为检查动作或参数修正。为抑制伪相关，引入稳定性约束与因果筛查，让模型在轻微扰动与工况变化下保持结论一致。评价解释质量时引入一致性与有效性两项指标，一致性衡量不同模型与不同批次的解释是否趋同，有效性衡量依据解释进行干预后是否带来风险降低。对在线学习设置审慎门槛，新参数在回放与小范围试用中通过考核后再进入全量部署，部署后持续监控偏移并保留回滚通道，确保改动在可控范围内逐步放大。在展示层提供分层仪表盘，管理层看到风险热力图与总体趋势，一线人员看到可执行清单与步骤进度。解释结果与处置规范一一对应，从观察到拆检再到复位都有文字与图示指引，减少知识鸿沟带来的偏差。为促进组织学习，把解释与实际处置的成功率按时间维度展现，提示哪类信号最值得优先关注。解释与告警共享统一的审计编号，任何一次查看与修改都进入日志，配合权限管理形成可追责的链路。对涉及安全红线的场景，解释面板只展示必要信息，避免误导性细节造成过度操作。

4 结语

深度学习为电气设备状态监测与故障预测提供了强大的表征与推断工具，其效能来自对象建模、数据治理与模型约束的协同。以统一词典与编码打通全链条，以自监督与迁移缓解标注压力，以边云协同与不确定性控制保障上线表现，配合滚动验证与闭环改进，监测系统便能在复杂工况下维持稳定收益。后续工作聚焦跨设备迁移与小样本鲁棒，把解释结果固化为可复用的检查清单，使算法持续转化为工程能力。在组织层面推进例行复盘与版本门禁，让每次改动都有来源与验证。

参考文献：

- [1] 唐小琳. 基于深度学习的新能源电站电气设备运维检测系统 [J]. 电气技术与经济, 2025, (07):196-198.
- [2] 栗嘉敏. 基于深度学习的电气设备故障预测与健康管理 [J]. 电气时代, 2025, (07):137-140.
- [3] 徐鸣阳. 基于深度学习的高压电气设备故障信号检测系统 [J]. 电气技术与经济, 2025, (06):193-195.
- [4] 孙刚. 基于深度学习的机械电气设备安全控制方法设计与实现 [J]. 电气技术与经济, 2025, (05):90-92.

作者简介：杨文杰 (1984.01—)，男，侗族，成都市锦江区，本科，工程师，研究方向为自动化。