

人工智能在水电设备故障预测与维护中的应用效果分析

杨博瀚¹, 王子元², 史宏博³

(1. 国家电网公司东北分部; 2. 国网东北分部绿源水力发电公司云峰发电厂; 3. 国网东北分部绿源水力发电公司太平湾发电厂)

【摘要】本研究构建融合长短期记忆网络(LSTM)与卷积神经网络(CNN)的预测模型,设计多源数据特征提取流程与模型训练机制,输出故障概率及剩余寿命指标,并嵌入在线监测平台,实现设备实时预警与维护策略自动生成,有效提升设备运行可靠性及系统智能化运维水平。

【关键词】人工智能;水电设备;故障预测;深度学习;智能维护;LSTM;CNN

中图分类号:TV738;TP18

DOI: 10.13655/j.cnki.ibci.2025.S2.125

Analysis of the Application Effect of Artificial Intelligence in Fault Prediction and Maintenance of Hydropower Equipment

YANG Bo-han¹, WANG Zi-yuan², SHI Hong-bo³

(1.Northeast Division of State Grid Corporation of China; 2.State Grid Northeast Branch Green Source Hydroelectric Power Company Yunfeng Power Plant; 3.State Grid Northeast Branch Green Source Hydropower Company Taiping Bay Power Plant)

【Abstract】This study constructs a prediction model integrating Long Short-Term Memory (LSTM) Network and Convolutional Neural Network (CNN), designs mechanisms for multi-source data feature extraction and model training, outputs indicators of fault probability and remaining useful life (RUL), and embeds the model into an online monitoring platform to realize real-time early warning and automatic generation of maintenance strategies, effectively improving the operational reliability of equipment and the level of intelligent operation.

【Keywords】artificial intelligence; hydropower equipment; fault prediction; deep learning; intelligent maintenance; LSTM; CNN

1 引言

随着水电站智能化、无人化发展,关键设备运行状态复杂多变,基于定期巡检与经验判断的传统模式难以满足运维需求。人工智能技术在智能感知、故障识别和预测维护中具备显著优势,能从复杂运行数据中挖掘关键特征,提升设备健康管理水平,已成为水电设备运维体系升级的重要支撑。

2 故障预测模型构建方法

2.1 多源运行数据特征工程与输入结构设计

水电设备运行会产生大量振动、电压电流、温度、转速、压力数据及运行日志,这类数据维度多样、时间跨度大,具有明显时序特征与工况依赖性。多源数据融合是统一不同采样频率、格式及噪声水平的信号特征,采用滑动窗口与重采样技术将高频物理量映射至固定步长时序样本,对缺失段插值滤波。

特征工程阶段基于信号统计指标、频域参数及工程先验构建高维特征空间,含最大值、均值、均方根、峭度等指标,引入STFT、CWT等时频分析方法保留瞬态非平稳特征。电气设备可额外引入三相不平衡因子与谐波畸变率。最终输入结构采用三维张量形式表示为:

$$X \in R^{B \times T \times F} \quad (1)$$

式(1)中: B 为样本批量数, T 为时间步长, F 为每一时间步上的特征维数。该结构为后续LSTM及卷积网络建模提供统一接口,可通过位置编码与归一化处理增强时间依赖建模效果。

2.2 基于LSTM与CNN的序列建模与故障分类机制

针对水电设备运行数据具备明显的时序相关性与局部特征模式,需构建兼具时序记忆与空间卷积提取能力的复合深度模型,以识别潜在故障模式与变异信号。其中,长短期记忆网络(Long Short-Term

Memory, LSTM)在长期依赖建模中具备记忆门控优势,可用于提取演化轨迹与趋势变换,而卷积神经网络(Convolutional Neural Network, CNN)则适用于局部时间窗内的异常信号检测与边缘轮廓识别。模型采用并联融合结构:LSTM通道处理归一化时间序列以保留动态演化趋势,CNN通道在时间轴维度执行一维卷积操作以提取局部显著特征。融合层采用全连接层与注意力机制组合,增强对关键特征权重的感知能力。最终,输出端通过Softmax函数实现多类故障标签的概率映射:

$$y = \text{Softmax}(W \cdot h + b) \quad (2)$$

式(2)中: h 为融合特征, W 与 b 分别为权重矩阵与偏置项, y 为各类故障预测概率。为适配多工况多机型环境,可引入多分支网络结构,按设备类型划分子模型;训练阶段采用标签平滑与样本重加权机制应对类别不平衡问题。

2.3 模型训练过程与预测标签优化策略

模型训练阶段,为保证深度模型的鲁棒性与可解释性,需构建大规模、多故障、全周期数据集,设计标签提取与样本切片策略。针对时间标签不全或误标的实际工况,预测标签由设备告警日志、故障维修记录与运行控制信号联合构建,基于时间窗口进行弱标签扩展,采用滚动样本生成策略提升训练样本量,增强模型对早期微弱信号的敏感性。

为兼顾分类准确性与时序一致性,采用加权交叉熵与时序平滑正则项联合优化的目标函数:

$$L = \sum_{i=1}^N \alpha_i \cdot \text{CE}(y_i, \hat{y}_i) + \lambda \cdot \sum_{i=1}^{T-1} \|\hat{y}_{i+1} - \hat{y}_i\|_2^2 \quad (3)$$

式(3)中: α_i 为样本权重, CE 为交叉熵损失, λ 为正则系数,第二项用于惩罚预测结果在时间维度的非平滑跳变,避免误报与漏报。模型训练采用Adam优化器,设动态学习率衰减策略,每轮迭代基于验证集精度与召回率调整早停条件,保存不同设备、故障类别上表现最优的子模型,实现个性化预测部署。

3 智能预测结果在设备维护决策中的集成应用

3.1 故障概率输出与剩余寿命估算方法设计

深度学习预测模型输出的多维时序数据,经后处理转化为各故障模式的条件概率分布,既体现设备健康状态,也作为后续维护策略制定的重要输入

变量。具体实现中,构建基于时间序列的预测窗口,将设备在 T 时刻的历史运行状态向量,映射至 $T+\Delta T$ 时刻的故障分类概率(ΔT 为模型预测步长)。该概率序列经指数平滑处理后,可反映潜在劣化路径上的故障趋势变化。

为量化设备退化进度,引入寿命回归模型对设备剩余寿命 RUL (Remaining Useful Life)进行动态预测:利用训练样本中每种故障演化轨迹对应的预测概率变化区间作为 RUL 函数输入,以指数退化模型为基础构建预测公式:

$$RUL(t) = \frac{\ln\left(\frac{P_{th}}{P(t)}\right)}{\lambda} \quad (4)$$

式(4)中: $P(t)$ 为 t 时刻预测输出的故障概率, P_{th} 为提前预警的阈值, λ 为由历史数据回归得到的增长系数。该表达式可基于预测结果计算预期寿命,且在预测曲线尚未剧烈上升前,即可判断设备进入临界退化期。此外, RUL 结果需结合设备工况动态修正,考虑水电站设备长期处于高水压、高载荷及间歇运行工况下的应力集中效应,模型中应引入工况敏感因子 β ,通过线性调整项校正 RUL 偏差。实际部署时,需针对水轮机导轴承、电磁调速器冷却系统、发电机励磁装置等关键子系统分别独立建模,确保故障概率输出的物理可解释性与剩余寿命评估的可控性^[1]。

3.2 融合预警结果的智能维护计划自动生成机制

面向水电设备智能维护调度场景,需将预测模型输出的故障概率、 RUL 、关键部件定位等结果,统一映射为可执行任务优先级排序模型,建立故障风险驱动的维护计划生成机制。为实现模型与决策系统的逻辑闭环,需构建设备健康评分函数 $S(i)$ (i 表示设备编号),该函数依赖预测故障概率、剩余寿命与停机影响因子组成的多变量函数,表达式如下:

$$S(i) = \omega_1 \cdot P_i + \omega_2 \cdot \frac{1 - RUL_i}{T_{max}} + \omega_3 \cdot I_i \quad (5)$$

式(5)中: P_i 为模型预测的目标故障概率; RUL_i 为剩余寿命估值; T_{max} 为设备参考寿命上限; I_i 为设备对站点运行的影响程度; $\omega_1, \omega_2, \omega_3$ 为各因素权重(满足 $\omega_1 + \omega_2 + \omega_3 = 1$)。通过对所有设备 $S(i)$ 排序,形成维护任务队列,进而触发基于优化算法的维护时序生成模块。调度策略采用带资源约束的变邻域搜索算法优化维护路径,满足预警窗口限制、设备停机同步

窗口、检修人力与备件约束等运维实际条件^[2]。

对于并联冗余的变压器组或备用电源系统,需引入逻辑容错约束条件,构建最低成本维护集,确保维护策略在安全冗余边界内运行。此外,预测结果与维护任务计划生成之间需采用语义映射机制,使维护工单包含预测时间戳、建议检修时限等关键字段,自动对接水电站 CMMS 系统或 EAM 系统的维护调度模块,完成任务从“预测→调度→执行”的全流程自动化闭环。

3.3 在线监测平台的部署架构与反馈闭环机制

具备高可用性、低时延及模型动态加载能力的在线监测平台,应包含边缘采集层、模型计算层与决策执行层。边缘采集层负责从振动传感器、电流互感器等多源设备中高频采集运行数据,数据经标准化处理为 JSON 格式,通过 MQTT 协议流式传输至模型计算层。

模型计算层集成基于 Docker 容器的推理引擎与模型热加载机制,支持 LSTM、CNN 等模型动态部署,且推理服务通过 TensorRT 加速,保障 10ms 内的模型响应时效。每次模型运行生成故障预测结果后,立即存入状态数据库,供后续维护系统调用^[3]。此外,平台需与主 SCADA 系统、CMMS 系统建立双向通信,制定对应通信协议,将预测标签同步写入设备历史数据库,形成结构化预警序列,同时触发维护工单自动生成。

闭环机制设计需包含模型自更新模块、反馈修正模块与人为干预接口。其中,模型自更新模块根据实际故障与预测结果的差异动态调整模型参数,通过增量学习策略使模型适应设备老化趋势;反馈修正模块通过采集维修后设备的状态数据,回传至训练样本库并标注预测误差位置,实现样本增强;人为干预接口允许维护人员对异常识别结果进行人工标注,作为后续模型纠偏依据。

平台架构还需具备可扩展性,支持接入风电等其他能源场景的设备模型,在站控级形成“数据感知—智能判断—闭环执行”的高频联动逻辑,实现预测驱动下真正“无人干预”的智能维护新模式。

4 应用效果评估与试点工程验证

为系统验证基于深度学习的故障预测模型与智能维护决策机制在实际水电设备运维场景中的适用性及效果,选取国内典型中小型水电站,基于其运行

数据开展现场试点。评估指标围绕预测准确率、预警提前时间、非计划停机率、维保响应时间及整体维护成本优化比等维度设定。

试点过程中,将 LSTM-CNN 组合预测模型分别部署于发电机轴承、电气控制系统与水轮机冷却模块,实时采集振动信号、电流偏移、电压异常等多源运行数据,输入预测框架并动态更新模型。同时采用时间窗口滑动与曲率增强机制提取关键特征序列,以概率输出形式反馈至智能维护调度系统,进而实现剩余寿命预测与故障风险分级控制。实际试点工程中,AI 预测系统与传统策略的对比效果数据如表 1 所示。

表1 实际试点工程中 AI 预测系统与传统策略对比效果数据

指标类型	传统方法数值	AI 预测系统数值	变化幅度/%
预测准确率/%	79.2	92.7	17.1
平均预警提前时间/天	4.6	12.3	167.4
非计划停机率/%	8.8	3.2	-63.6
平均维护响应时间/h	7.5	3.9	-48
维保成本下降幅度/%	—	26.5	—

由表 1 数据可知,AI 预测系统的预测准确率较传统方法提高 17.1%;平均预警提前时间延长至 12.3 天,提升幅度达 167.4%,显著增强预防性维护能力;非计划停机率与平均维护响应时间分别降低 63.6%、48%,体现系统在运行稳定性与运维响应效率上的双重优化;维保成本下降 26.5%,提升经济效益。

5 结语

本研究围绕水电设备智能化运行需求,构建融合 LSTM 与 CNN 的深度学习预测模型,设计涵盖多源特征提取、序列建模、标签优化与故障分类的算法体系,集成故障概率输出与 RUL 评估机制,实现对关键部件运行状态实时感知与预警决策。

参考文献

[1] 李清升, 吴海涛. 基于人工智能的电气设备故障预测与维护策略研究[J]. 中国设备工程, 2025 (5): 26-28.
[2] 雷庆连. 探讨人工智能技术在汽车电器故障预测与维修中的应用[J]. 大众汽车, 2025 (2): 130-132.
[3] 汲晓飞. 基于人工智能的水利水电设备状态监测与预测技术研究[J]. 中国高新科技, 2024 (10): 31-33.