

人工智能驱动的电力终端异常行为识别与预测维护系统设计

卢俊杰 朱宝龙 刘 群

南方电网超高压输电公司昆明局 云南 昆明 650000

摘要: 随着电力终端规模扩大与运行环境复杂化,传统运维方式面临效率低、成本高的挑战。本文设计了一种人工智能驱动的电力终端异常行为识别与预测维护系统,采用分层架构实现数据高效采集与处理,融合多源数据与深度学习模型实现精准异常检测,结合物理退化与数据驱动模型预测设备剩余寿命,并通过多目标优化与强化学习动态制定维护策略。实验验证了系统在降低误报率、控制预测误差及减少维护成本方面的显著优势。

关键词: 人工智能驱动; 电力终端异常行为识别; 预测维护系统设计

引言: 随着电力系统规模不断扩大,电力终端数量急剧增多且运行环境愈发复杂,传统人工巡检与基于固定阈值的监测方式,难以精准、及时地识别终端异常行为并预测故障。这不仅导致设备非计划停机频繁,影响供电可靠性,还增加了运维成本。人工智能技术凭借强大的数据处理与模式识别能力,为解决这些问题提供了新途径。设计人工智能驱动的电力终端异常识别与预测维护系统,成为保障电力系统稳定运行的关键。

1 人工智能驱动的电力终端异常行为识别与预测维护系统总体设计

1.1 系统架构设计

(1) 分层架构: 数据采集层通过传感器、智能电表等设备,实时采集电力终端电压、电流、温度等运行数据,保障数据源头全面性;边缘计算层部署轻量化AI模型,对采集数据进行实时过滤与初步分析,降低云端数据传输压力;云端分析层依托高性能计算资源,运行复杂AI算法开展深度异常识别与预测;用户交互层以Web、APP形式,为运维人员提供数据查询、预警查看等可视化操作界面。(2) 功能模块划分: 数据预处理模块对原始数据进行去噪、补全、标准化处理,提升数据质量;异常检测模块基于AI算法识别终端过载、漏电等异常行为;预测维护模块通过分析设备运行趋势,预测故障发生时间与类型;可视化预警模块将异常信息、预测结果以图表、告警弹窗形式展示,及时提醒运维人员。

1.2 关键技术选型

(1) 异常检测算法对比: LSTM擅长捕捉时序数据依赖关系,适用于电力终端连续运行数据的异常识别,但训练耗时较长;Isolation Forest对离群数据敏感,训练速度快,不过对复杂时序异常检测精度较低;

Autoencoder通过重构数据识别异常,能处理高维数据,却易受正常数据波动影响,实际应用中需结合场景选择或融合使用。(2) 预测模型选择: Prophet模型对周期性数据预测效果好,适合电力负荷等周期性明显的场景;Transformer模型能捕捉长序列数据特征,预测精度高,但计算成本较高;混合模型结合多种模型优势,如Prophet与Transformer融合,可兼顾周期性与长序列特征,提升预测可靠性。(3) 边缘计算与云计算协同机制: 边缘计算负责实时数据预处理、简单异常检测与本地告警,减少无效数据传输;云计算接收边缘上传的关键数据,进行深度分析与模型训练,将优化后的模型参数下发至边缘节点;通过边缘与云端的数据交互、模型协同,实现“本地快速响应+云端深度处理”的高效运行模式,保障系统实时性与准确性^[1]。

2 人工智能驱动的电力终端异常行为识别方法

2.1 数据特征工程

(1) 多源数据融合: 针对电力终端多维度运行数据,采用“时空对齐-数据补全-特征融合”三步法处理。先基于时间戳同步电压(采样率50Hz)、电流(采样率50Hz)、温度(采样率1Hz)、振动(采样率1kHz)数据,解决采样频率差异问题;再通过插值法补全传感器故障导致的缺失数据,保证数据完整性;最后采用注意力加权融合算法,对不同数据赋予差异化权重(如电流、电压权重0.3,温度、振动权重0.2),突出关键参数对异常识别的影响,形成统一特征矩阵。(2) 特征提取方法: 时域统计提取均值、方差、峰值等12项统计特征,反映数据整体分布规律;频域分析通过傅里叶变换将时域数据转换至频域,提取谐波分量、频谱峰值等特征,捕捉设备异常时的频率特征变化(如电机故障时的

特定频率峰值)；小波变换采用db4小波基函数，对非平稳振动数据进行多尺度分解，提取高频段故障特征与低频段趋势特征，三类特征组合形成维度为64的特征向量，为后续模型输入提供丰富信息。

2.2 基于深度学习的异常检测模型

(1) 改进的LSTM-Autoencoder无监督学习框架：在传统Autoencoder基础上，encoder与decoder均采用双向LSTM结构，增强对时序数据前后依赖关系的捕捉能力；引入残差连接缓解深层网络梯度消失问题，将输入特征直接传递至输出层，提升模型训练稳定性；训练过程以正常运行数据为样本，通过最小化输入与重构输出的MSE损失，使模型学习正常数据分布，异常数据因重构误差过大被识别。(2) 注意力机制增强模型对关键特征的捕捉能力：在encoder输出层加入多头注意力模块，计算各特征维度的注意力权重，对电流突变、温度骤升等关键异常特征赋予更高权重(权重占比提升至0.6-0.8)，抑制噪声特征干扰；同时在decoder层引入时序注意力，聚焦异常发生前后的关键时间片段，进一步提升模型对早期微弱异常的识别灵敏度^[2]。(3) 模型轻量化设计：采用知识蒸馏技术，以复杂LSTM-Autoencoder为教师模型，简单CNN-Autoencoder为学生模型，通过迁移教师模型的概率分布知识，在保证识别精度(下降不超过2%)的前提下，将模型参数规模压缩至原模型的1/5；结合INT8量化压缩，将模型权重从32位浮点数转为8位整数，减少边缘设备内存占用，提升推理速度。

2.3 动态阈值调整策略

(1) 基于统计分布的阈值自适应算法：对模型输出的重构误差，采用核密度估计(KDE)拟合正常数据误差分布，计算99.5%置信区间对应的误差值作为初始阈值；当新的正常数据输入时，实时更新误差分布参数，动态调整阈值上下限，避免因设备老化导致正常误差漂移引发误报，实验验证该算法可使误报率降低15%-20%。(2) 结合设备历史运行数据的动态更新机制：建立设备生命周期数据库，按季度划分运行阶段(磨合期、稳定期、老化期)，针对不同阶段分别训练阈值调整模型；例如稳定期设备误差波动小，阈值设定较严格；老化期设备正常误差增大，阈值适度放宽；通过阶段匹配与历史数据回溯，实现阈值与设备运行状态的精准适配，保障异常识别的准确性与灵活性。

3 人工智能驱动的电力终端异常行为预测维护策略设计

3.1 设备剩余寿命(RUL)预测

(1) 基于序列到序列(Seq2Seq)模型的预测方法：

以电力终端多源时序数据(电压、温度等)为输入，采用Encoder-Decoder架构构建Seq2Seq模型。Encoder通过多层LSTM将历史运行数据编码为高维特征向量，捕捉设备退化趋势；Decoder基于该向量输出未来一段时间内的设备状态序列，结合预设故障阈值反推RUL。模型训练中引入注意力机制，强化对设备退化关键阶段数据(如温度骤升时段)的关注，提升预测精度，实验验证其RUL预测误差可控制在10%以内。(2) 融合物理退化模型与数据驱动模型：物理退化模型基于电力终端设备原理(如绝缘老化公式)，建立退化量与运行时间的解析关系，明确设备理论寿命边界；数据驱动模型(如梯度提升树)利用实际运行数据修正物理模型参数，弥补理论假设与实际工况的偏差。通过加权融合两种模型输出结果，当设备运行数据充足时，侧重数据驱动模型预测结果；当数据稀缺(如新型终端)时，以物理模型结果为基础，实现全生命周期内RUL的精准预测^[3]。

3.2 维护决策优化

(1) 多目标优化问题建模：构建以“最小化维护成本、最大化设备可靠性、最短化停机时间”为目标的优化模型。维护成本包含备件采购、人工费用；可靠性通过设备无故障运行概率量化；停机时间关联生产损失。采用非支配排序遗传算法(NSGA-II)求解多目标问题，生成Pareto最优解集，供运维人员根据实际场景(如用电高峰期优先保障可靠性)选择决策方案。(2) 强化学习驱动的动态维护策略生成：将维护决策过程建模为马尔可夫决策过程，以设备当前状态(如RUL、运行负荷)为状态空间，维护动作(如立即维护、延迟维护)为动作空间，综合成本与可靠性的收益值为奖励函数。通过深度Q网络(DQN)训练智能体，使其在不同工况下自主学习最优维护时机，例如在用电低谷期优先执行非紧急维护，在设备RUL低于阈值时触发紧急维护，实现维护策略的动态自适应调整。

3.3 预警与干预机制

(1) 分级预警体系：依据设备RUL预测结果与实时异常程度划分预警等级。一级异常(RUL > 30天，轻微参数波动)：系统自动推送提示信息，无需立即干预；二级异常(10天 < RUL ≤ 30天，关键参数超限)：触发声光告警，通知运维人员制定维护计划；三级异常(RUL ≤ 10天，严重性能退化)：启动紧急预警，联动切断非关键负荷，避免故障扩大。(2) 维护任务自动派发与执行反馈闭环：预警触发后，系统基于运维人员位置、技能匹配度及任务紧急程度，通过运维APP自动派发维护任务，同步推送设备位置、故障类型及所需备件信

息。运维人员完成维护后，在APP上传执行记录（如更换部件、测试数据），系统校验设备状态是否恢复正常，形成“预警-派发-执行-反馈”的闭环管理，确保维护任务高效落地^[4]。

4 人工智能驱动的电力终端异常行为识别与预测维护系统实现与实验验证

4.1 实验环境与数据集

（1）测试平台配置：边缘设备选用NVIDIA Jetson Xavier NX（算力21TOPS），支持轻量化AI模型部署，搭配高精度传感器组—电流传感器（精度0.1%FS）、温度传感器（量程-40~125℃，精度±0.5℃）、振动传感器（采样率1kHz），实时采集电力终端运行数据；云端平台采用CPU Intel Xeon Gold 6338（32核）+GPU NVIDIA A100（40GB显存），用于模型训练与深度数据分析，保障实验算力支撑。（2）公开数据集与自建数据集：公开数据集采用IEEE PES电力设备故障数据库（含变压器、开关柜等终端的过载、短路故障数据，共10万+条时序样本）；自建数据集通过现场部署传感器，采集某变电站100台10kV终端设备1年运行数据（含正常状态与12类异常状态数据，总量8万条），经标注与清洗后，按7:2:1划分训练、验证、测试集，确保数据覆盖性与真实性。

4.2 对比实验设计

（1）基准方法：传统阈值法（基于设备额定参数设定固定阈值）、支持向量机（SVM，经典机器学习异常检测方法）、普通LSTM（未改进的时序异常检测模型），与本文提出的改进LSTM-Autoencoder模型及融合预测模型进行性能对比，验证所提方法的优越性。（2）评价指标：异常检测环节采用准确率（正确识别样本占比）、召回率（异常样本检出率）、F1值（准确率与召回率调和平均）、误报率（正常样本误判为异常的比例）；预测维护环节新增预测提前量（故障发生前的预测时间）、RUL预测误差（预测值与实际值偏差率）、维护成本降低比例（对比传统定期维护成本），全面衡

量系统性能。

4.3 实验结果分析

（1）异常检测性能对比：所提模型ROC曲线下面积（AUC）达0.98，显著高于传统阈值法（0.72）、SVM（0.85）、普通LSTM（0.91）；混淆矩阵显示其误报率仅2.1%，召回率达97.3%，表明对复杂异常的识别能力更强，有效减少运维冗余工作。（2）预测维护效果验证：RUL预测误差控制在8.5%以内，较普通LSTM模型（15.2%）降低44%；基于强化学习的维护策略使年度维护成本降低28%，停机时间缩短32%，验证了预测维护策略的经济性与实用性。（3）边缘部署性能测试：轻量化模型在边缘设备上推理延迟仅85ms，满足实时检测需求（要求<100ms）；CPU占用率35%、内存占用率28%，低于普通模型（CPU62%、内存51%），证明其适配边缘端资源受限场景。

结束语

本系统设计借助人工智能技术，实现了对电力终端异常行为的高效识别与精准预测维护。通过分层架构、多源数据融合及深度学习模型，显著提升了异常检测的准确性与及时性。融合物理与数据驱动的预测方法，结合多目标优化与强化学习策略，有效降低了维护成本，延长了设备寿命。未来，随着技术持续发展，系统将进一步优化算法、拓展应用场景，为电力系统的安全稳定运行提供更坚实有力的保障。

参考文献

- [1] 邹宇. 基于智能技术的电力系统故障诊断与恢复机制分析[J]. 集成电路应用, 2024, (07): 70-71.
- [2] 姜俊秋. 基于人工智能的电力系统故障检测与自动修复方法研究[J]. 电气技术与经济, 2024, (03): 22-24.
- [3] 王明菲. 电力系统中基于人工智能的故障诊断与恢复研究[J]. 中国品牌与防伪, 2024, (05): 56-57.
- [4] 郭佳强. 基于人工智能的电力系统故障诊断与恢复策略研究[J]. 中华纸业, 2024, (09): 86-88.