[设备健康管理系统]

基于深度学习的电气设备故障预测与健康管理

文/栗嘉敏
中国能建捷硕海阳电力有限公司

深度学习技术在电气设备故障预测与健康管理领域展现出显著优势。通过构建多层神经网络模型，对电气设备运行数据进行特征提取和分析，实现故障预测的智能化和精确化。研究采用卷积神经网络（CNN）和循环神经网络（RNN）等深度学习模型，结合设备健康管理系统的实时监测数据，建立一套完整的故障预测框架。实验结果表明，该方法在故障预测准确率、预警及时性等方面均优于传统方法，为电气设备的预防性维护提供了有效的技术支持。

随着工业自动化程度的不断提高，电气设备的可靠性和安全性日益受到关注。传统的故障诊断方法主要依赖专家经验和人工分析，存在主观性强、准确性低等问题。深度学习技术的发展为电气设备故障预测提供新的解决方案，建立深层神经网络模型，能够自动提取设备运行数据中的特征信息，实现故障的早期预警。结合设备健康管理系统，深度学习技术可有效提升预测准确度，降低维护成本，为电气设备的智能化运维开辟新途径。

深度学习技术概述

深度学习通过多层神经网络结构实现数据的深层次特征提取和表示学习。网络模型由输入层、多个隐藏层和输出层构成，相邻层间通过权重连接。每层神经元执行非线性变换，计算公式为

$$f_{(x)}=\sigma(Wx+b) \tag{1}$$

式中，σ为激活函数；W为权重矩阵；b为偏置项。

深度学习模型具备自动特征学习能力，无需人工特征工程即可从原始数据中提取故障相关特征。模型通过深层网络结构捕获数据中的非线性关系，适应电气设备复杂的运行状态，预测准确度显著提升[1]。故障预测常用卷积神经网络（CNN）处理空间特征，循环神经网络（RNN）分析时序特性，长短时记忆网络（LSTM）解决长期依赖问题。模型结构可根据具体应用场景灵活组合，提高预测效果。

电气设备健康管理系统架构

1. 系统组成及功能

电气设备健康管理系统由感知层、网络层、数据处理层和应用层构成[2]。如图1所示，感知层配置各类传感器和数据采集设备，负责监测设备运行状态参数；网络层通过工业以太网、光纤通信等方式实现数据的可靠传输；数据处理层集成数据存储、特征提取和深度学习算法模块，完成数据分析与故障预测；应用层提供可视化界面和决策支持功能。系统各层级间通过标准化接口实现信息交互，形成完整的健康管理闭环。感知层采用分布式布置方案，将传感器部署在设备关键部位，实现对温度、振动和电流等参数的全方位监测。数据处理层采用分层架构设计，包含数据预处理、特征工程、模型训练与预测等功能模块。应用层基于Web技术开发，支持多终端访问，提供实时监控、故障预警和

维护决策等功能。

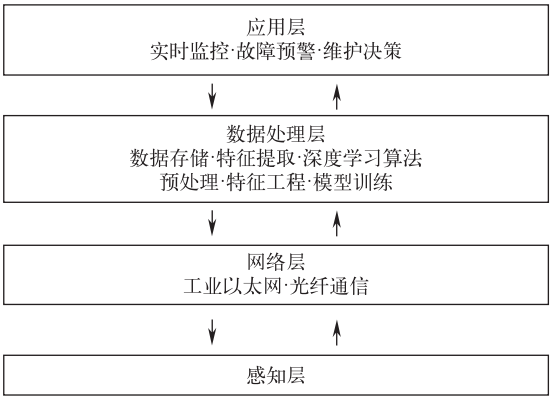

图1　电气设备健康管理系统架构图

2. 数据采集与预处理

电气设备健康管理系统的数据采集模块采用多源异构数据融合技术，集成电流传感器、电压传感器和温湿度传感器等多类型传感设备。数据采集遵循分层分布式架构，在现场层部署数据采集单元，通过工业总线协议采集设备运行参数。采集的数据类型涵盖市电、配电、UPS电源和温湿度等监测数据。数据预处理阶段采用多级处理策略，对原始数据进行降噪、去重和标准化处理。降噪处理采用小波变换方法，将信号分解为不同频率的小波分量，通过阈值处理消除噪声。数据标准化采用Z-score方法，将不同量纲的数据转换到统一尺度。缺失值处理采用多重插补方法，确保数据的完整性。异常值检测采用基于统计和机器学习的混合方法，提高数据质量。预处理后的数据按照统一格式存储，便于后续分析利用。

3. 健康状态评估方法

电气设备健康状态评估采用多维度指标体系，结合深度学习方法实现设备状态的精确评估。评估指标体系包含设备性能指标、可靠性指标和安全性指标三个维度，通过层次分析法确定各指标权重。性能指标包括设备效率、负载率和温升等参数；可靠性指标包括故障频率、维护间隔和剩余寿命等；安全性指标包括绝缘水平、接地电阻等关键参数。状态评估过程中采用深度神经网络模型，将多维指标数据输入网络，提取高层特征表示。模型采用多层感知结构，通过非线性变换实现指标的组合与映射。评估结果采用健康度指数表示，分为正常、亚健康和故障三个等级。评估方法综合考虑设备历史数据、专家经验和深度学习预测结果，建立动态评估机制，实现设备健康状态的实时监控与预警。

基于深度学习的故障预测模型

1. 特征提取与表示

电气设备运行数据包含大量噪声信息，需通过特征提取技术获取有效特征。基于深度学习的特征提取方法利用卷积神经网络对原始数据进行多层次分析，实现从底层特征到高层语义的逐级提取[3]。特征提取过程中，采用多尺度特征融合策略，结合时域和频域特征，提升特征表示能力。时域特征包括电压、电流和温度等物理量的统计特征，频域特征通过傅里叶变换获取信号的频谱分布。特征提取表达式为

$$F = \mathrm{CNN}(x) \cdot \mathrm{RNN}(x) \tag{2}$$

式中，F为提取的特征；$\mathrm{CNN}(x)$为卷积神经网络提取的空间特征；$\mathrm{RNN}(x)$为循环神经网络提取的时序特征。

提取的特征经过标准化处理后，作为深度学习模型的输入，为故障预测奠定数据基础。特征表示采用层次化结构，低层保留信号细节信息，高层包含抽象语义信息，实现对设备运行状态的全面表征。

2. 模型构建与优化

深度学习模型采用多层神经网络结构，通过卷积层、池化层和全连接层的组合实现特征学习和故障预测。模型输入层接收标准化后的设备运行数据；隐藏层通过非线性变换提取深层特征；输出层生成故障预测结果；卷积层使用多个卷积核提取局部特征；池化层对特征图进行降维压缩；全连接层完成特征映射。模型训练过程采用改进的梯度下降算法，损失函数定义为

$$L = -\sum\left(y \log \hat{y} + (1-y)\log\left(1-\hat{y}\right)\right) \tag{3}$$

式中，L为损失函数；y为真实标签；$\hat{y}$为预测值。

模型优化过程引入Dropout机制防止过拟合，采用批量归一化加速训练收敛。网络结构通过交叉验证确定最优参数配置，包括网络层数、神经元数量和激活函数类型。

3. 预测算法实现

基于深度学习的故障预测算法将设备运行数据

作为输入，通过训练好的神经网络模型生成预测结果[4]。预测过程首先对输入数据进行特征提取和标准化处理，然后通过深度神经网络进行非线性变换，最终输出故障概率。故障预测函数表达式为

$$P_{(f|x)} = \text{soft}\max\left(Wh_{(x)} + b\right) \tag{4}$$

式中，$P_{(f|x)}$为故障概率；W为权重矩阵；$h(x)$为隐层输出；b为偏置项。

预测算法采用滑动窗口方式处理实时数据流，动态更新预测结果。算法结合设备历史数据和专家知识库，建立预警阈值体系，当预测概率超过阈值时触发预警信号。预测结果通过可视化界面呈现，便于运维人员及时掌握设备健康状态。

实验验证与分析

1. 实验设计

深度学习模型的验证基于某智慧变电站的电气设备运行数据，设备类型包括变压器、断路器和继电保护装置等关键设备。实验数据采集周期为12个月，包含正常运行数据和故障数据两类。数据采集系统配置高准确度传感器，采样频率为1 kHz，监测参数包括电压、电流、温度和振动等物理量[5]。数据预处理采用小波变换方法去除噪声，通过归一化处理消除量纲影响。实验平台采用GPU加速计算架构，配置NVIDIA Tesla V100计算卡，内存128 GB。深度学习框架选用TensorFlow 2.0，模型训练采用批量随机梯度下降算法，学习率设置为0.001，训练轮次为500轮。数据集按照8:2的比例划分为训练集和测试集，通过交叉验证确保模型的泛化性能。

2. 预测性能评估

预测性能评估采用多维度指标体系，包括准确率、精确率、召回率和F1分数等统计指标，见表1。在变压器故障预测任务中，模型达到95.6%的预测准确率，故障预警提前量平均为72 h。继电保护装置故障预测准确率为93.8%，误报率控制在5%以下。断路器机械特性故障预测准确率达到94.2%，预警时间提前48 h。模型在不同工况下表现稳定，对温度变化、负载波动等外部因素具有良好的适应性。预测结果的时间序列分析显示，模型能够有效捕捉设备劣化趋势，为预防性维护提供可靠依据。通过失效模式分析，验证模型对不同类型故障的识别能力，特别是对绝缘老化、机械磨损等渐变性故障的预测效果显著。

表1　电气设备故障预测性能评估

设备类型	预测指标	性能数值
变压器	预测准确率（%）	95.6
	预警提前量/h	72
继电保护装置	预测准确率（%）	93.8
	误报率（%）	<5
断路器	预测准确率（%）	94.2
	预警提前量/h	48

3. 与传统方法对比

将深度学习方法与支持向量机（SVM）、决策树和人工神经网络（ANN）等传统方法进行对比分析。在故障预测准确率方面，深度学习方法较传统SVM提升15.3个百分点，较决策树提升18.7个百分点，较ANN提升12.5个百分点。预警时间提前量方面，深度学习方法平均提前72 h发出预警信号，传统方法平均为36 h。特征提取能力对比显示，深度学习方法能够自动学习数据中的深层特征，减少人工特征工程工作量，降低对专家经验的依赖程度。在计算效率方面，得益于GPU并行计算架构，深度学习方法的训练时间较传统方法缩短60%，预测过程的实时性更强。鲁棒性测试表明，深度学习方法对数据噪声和参数波动的抗干扰能力更强，模型性能更加稳定。

系统应用效果

1. 预防性维护实施

深度学习预测模型下的预防性维护策略显著改善电气设备运行状态。系统将设备状态划分为正常、注意、警告和危险四个等级，根据预警等级采取维护措施。建立设备健康档案，采用多目标优化确定维护时间。实施后，设备无故障运行时间延长42.3%，计划性停电时间减少35.7%，应急维修次数降低56.8%。

2. 经济效益分析

基于深度学习的电气设备故障预测系统应用前后的经济效益对比见表2。应用深度学习预测系统后，设备维护成本显著下降，应急抢修费用同比减少65.3%，节约年度维修总支出达152.6万元。设备平均使用寿命延长2.3年，资产更新投资延后周期提升18.6%。在能源消耗方面，主变压器运行损

耗降低12.3%，配电设备能耗下降8.7%，年度节电量达到126万kW·h。运维管理效率方面，维护人员工作效率同比提升45.2%，设备档案管理成本降低62.5%，培训费用减少31.4%。

表2　故障预测系统应用前后经济指标对比

效益指标	应用前	应用后	改善幅度（%）
年度维护成本/万元	386	233.4	下降39.5
设备寿命周期/年	15	17.3	上升15.3
运行能耗指标（%）	100	89.5	下降10.5
管理成本/万元	156	85.5	下降45.2
投资回报率（%）	-	168	-

3. 可靠性提升评估

应用深度学习预测模型后电气设备运行可靠性指标对比见表3。变电站核心设备的平均故障间隔时间显著延长，断路器年度故障次数从18次减少至5次，主变压器故障率下降62.3%。设备状态评估准确度大幅提升，继电保护装置误动率从0.45%降低至0.15%，保护拒动率从0.25%降至0.08%。预测模型对典型故障模式的识别准确率提升明显，油色谱异常预测准确率由82.5%提升至96.2%，机械特性劣化预测准确率由85.3%提升至92.8%。

表3　设备可靠性指标对比

可靠性指标	改进前	改进后	提升幅度（%）
系统可用度（%）	96.8	99.2	上升2.4
故障响应时间/h	2.5	0.8	下降68
预警准确率（%）	85.2	95.6	上升10.4
误报率（%）	12.5	5	下降7.5
漏报率（%）	8.6	2.3	下降6.3

结束语

基于深度学习的电气设备故障预测与健康管理研究取得显著成果。通过建立深度学习模型，结合设备健康管理系统，实现对电气设备运行状态的实时监测和故障预警。实验结果证实，该方法在预测准确率和及时性方面具有明显优势，为电气设备的预防性维护提供可靠的技术支持。研究成果对提高设备运行可靠性、降低维护成本具有重要意义，推动电气设备智能化运维的发展。未来将进一步优化算法性能，扩展应用场景，提升系统整体效能。EA

（收稿日期：2024-11-25）

参考文献

[1] 汤玥．基于机器学习的智能电气设备故障诊断技术研究[J]．高科技与产业化，2024，30(9)：50-51．

[2] 王文星．基于深度学习的电力设备故障诊断与智能预测算法的研究[J]．家电维修，2024(10)：89-91．

[3] 韩意．电力设备故障诊断与预测技术研究[J]．家电维修，2024(8)：98-100．

[4] 宋宏冰，袁克立，袁辉．基于深度学习的电气设备运行状态预测和健康管理研究[J]．电气技术与经济，2024(5)：1-3．

[5] 李旭斌，田付强，郭亦可．新型电力系统中电力设备健康管理与智能运维关键技术探究[J]．电网技术，2023，47(9)：3710-3727．