

[故障诊断系统]

基于人工智能的电气设备故障智能诊断系统研究

文/李强
合肥维信诺科技有限公司

随着电力系统规模不断扩大和复杂度持续提升，传统的电气设备故障诊断方法已难以满足现代电力系统的运维需求。针对电气设备故障诊断的实时性和准确性问题，提出一种基于人工智能的故障诊断方法，通过深度学习、计算机视觉和大数据分析等技术的融合应用，实现从一次设备到二次设备的全面监控与智能诊断。研究表明，该方法能够有效提升故障诊断的准确率和实时性，为电力系统的智能化运维提供新的技术路径。

电气设备是电力系统的核心组成部分，其运行状态直接关系到电力系统的安全稳定运行。随着智能电网建设的深入推进，电气设备的种类和数量急剧增加，设备运行环境日益复杂，传统的人工巡检和经验诊断方式已无法满足现代电力系统的运维需求。特别是在设备故障的早期预警和精准诊断方面，传统方法存在准确度低、效率差和滞后性强等问题。

在人工智能技术快速发展的背景下，将深度学习、计算机视觉和大数据分析等技术应用于电气设备故障诊断领域，可以有效解决上述问题。通过构建智能化的故障诊断系统，实现设备状态的实时监测、故障的提前预警和精准诊断，对提升电力系统运维水平具有重要意义。

故障诊断系统原理

在电力系统运行维护过程中，设备故障的及时诊断和预警至关重要。为实现电气设备状态的智能监测与故障预警，本研究深入分析故障诊断的基本原理，构建完整的诊断系统框架，如图1所示。




图1 故障诊断系统框架

1. 基本原理

电气设备的运行状态是由多个关键参数共同决定的，用多维参数空间描述，包括电气量、环境量

和设备本体特征量。为实现对设备状态的精确表征,本研究构建多维状态参数集,计算式为

$$S_i = V_i, I_i, T_i, H_i, \theta_i \quad (1)$$

式中, V_i, I_i 分别为设备的电压、电流有效值; T_i 为关键部位温度; H_i 为环境湿度; θ_i 为设备状态特征参数集, 包括振动、噪声和局部放电等关键指标。

这些参数的实时监测为故障诊断提供了基础数据支撑。

基于状态参数集合, 系统构建了完整的功能模型

$$F = D(S_i), P(S_i), A(S_i) \quad (2)$$

式中, $D(S_i)$ 为数据采集函数, 负责多源传感数据的同步采集; $P(S_i)$ 为数据处理函数, 完成数据预处理、特征提取和数据融合; $A(S_i)$ 为智能诊断函数, 基于深度学习实现故障识别与预警。

在系统实际运行过程中, 首先通过分布式传感网络架构进行数据采集。系统采用0.2级电子式互感器实时监测电压、电流参数, 采样频率达10 kHz, 确保电气参数测量的高准确度; 采用PT100铂热电阻监测设备温度, 测量准确度达到 $\pm 0.1^\circ\text{C}$, 实现温度场的精确监测; 环境湿度采用电容式传感器进行测量, 准确度为 $\pm 2\%\text{RH}$, 有效监控设备运行环境; 针对振动、噪声等特征参数, 根据具体监测需求选用压电式加速度传感器、超声传感器等专业传感设备, 实现全方位的状态监测。

数据处理环节采用一套完整的自适应预处理方案。系统首先利用小波阈值滤波技术对采集信号进行降噪处理, 通过自适应选择最优分解层数, 有效去除测量噪声的同时保留有效信号特征。随后, 采用Z-score标准化方法对不同类型的数据进行归一化处理, 解决不同物理量之间量纲不一致的问题。在特征提取阶段, 系统综合运用时域、频域和时频域分析方法, 全面提取故障特征信息。最后, 通过改进的D-S证据理论方法实现异构数据的有效融合, 为后续故障诊断提供可靠的数据基础。

在智能诊断层面, 采用深度学习技术构建故障诊断模型。通过设计多分支并行卷积网络结构, 系统能够同时提取多个尺度的特征信息, 提升特征提取的全面性和准确性。在模型优化方面, 通过在损失函数中引入正则化项和类别权重, 解决过拟合问题, 并提高对少数类故障样本的识别能力。为解决

实际应用中样本不平衡的问题, 系统采用迁移学习策略, 充分利用先验知识提升模型性能。在故障预警决策时, 基于模型的概率输出设计自适应预警阈值, 实现准确的故障预警。

这种层次化的系统设计通过各功能模块的有机结合, 实现电气设备状态的实时监测与故障预警。系统采用标准化接口实现模块间的数据交互, 确保系统的可扩展性。同时, 分布式架构和边缘计算技术的应用可以提升系统的实时性能, 为电气设备的智能运维提供强有力的技术支撑。

2. 数据融合模型

在电气设备状态监测过程中, 来自不同传感器的多源异构数据存在时序相关性、数据冗余以及不确定性等特点。为有效处理这些复杂数据, 本研究对传统Dempster-Shafer证据理论进行改进, 提出一种基于时序权重的多源数据融合方法。改进后的数据融合模型可表示为

$$m(A) = \sum_{B \cap C = A} \frac{m_1(B)m_2(C)}{1-K} \cdot \omega(t) \quad (3)$$

为体现数据的时效性, 引入时序权重函数

$$\omega(t) = e^{-\lambda(t-t_0)} \quad (4)$$

式中, λ 为时间衰减系数, 反映了历史数据可信度随时间的衰减速率; t_0 为基准时间点, 用于标定时间起点; $\omega(t)$ 为时序权重函数, 用于动态调整不同时刻数据的权重。

这种设计使得系统能够更多地关注最新的监测数据。

在数据融合实现过程中, 首先对多源传感数据进行时间对齐和预处理。系统采用滑动时间窗口技术, 将连续的数据流离散化为时间序列片段。对于每个时间窗口内的数据, 基于传感器的测量准确度和可靠性, 确定基本概率分配函数 $m_1(B)$ 和 $m_2(C)$ 。这些基本概率分配反映不同证据源对故障假设的支持度。

冲突因子 K 用于表征不同证据源之间的矛盾程度, 其计算考虑传感器的工作状态和数据质量。当检测到传感器数据异常或不同证据源之间存在显著冲突时, 系统会自适应调整相应证据的权重, 以降低不可靠数据的影响。通过引入时序权重函数 $\omega(t)$, 系统能够动态调整不同时刻数据的重要性, 使得较新的数据在融合过程中具有更高的权重, 从

而提升融合结果的时效性。

时间衰减系数 λ 的选取是影响融合效果的关键因素。通过大量研究分析,发现当 λ 取值在0.1~0.3范围内时,系统能够较好地平衡历史数据的参考价值 and 实时数据的时效性。对于快速变化的参数(如电压、电流),采用较大的 λ 值以突出最新数据的重要性;对于缓变参数(如温度),则选用较小的 λ 值以充分利用历史信息。

为提高算法的计算效率,系统采用递推式计算方法,避免对历史数据的重复处理。同时,通过设置证据累积阈值,在保证融合准确度的前提下实现计算复杂度的优化。该数据融合模型通过有机结合D-S证据理论和时序权重机制,实现对多源异构数据的动态融合,为后续的故障诊断提供可靠的数据基础。

3. 实时监测机制

电气设备的健康状态评估是一个复杂的多参数动态过程,需要综合考虑设备运行过程中的各类状态特征。为实现对设备状态的精确实时评估,本研究提出一种基于深度学习的健康度评估模型

$$H(t) = f\left(\sum_{i=1}^n \alpha_i S_i(t)\right) \quad (5)$$

式中, $H(t)$ 为 t 时刻的设备健康度指标; α_i 为各特征参数的动态权重系数; $S_i(t)$ 为 t 时刻的状态特征参数; f 为基于深度神经网络构建的非线性映射函数。

监测机制实现过程中,首先采用多层感知机(MLP)构建非线性映射函数 f 。该网络包含多个隐藏层,每层使用ReLU激活函数提升网络的表达能力。为避免过拟合问题,在网络中引入Dropout层和 L_2 正则化,提高模型的泛化性能。输出层采用Sigmoid激活函数,将健康度指标归一化到[0,1]区间,便于状态评估和预警。

特征权重系数 α_i 的确定是模型设计的关键环节。本研究提出基于注意力机制的动态权重分配方法。通过设计多头注意力模块,系统能够自适应地捕获不同特征参数之间的相关性,并根据当前运行状态动态调整各参数的重要性权重。这种方法相比传统的固定权重方案,能更好地适应设备运行状态的动态变化。

为提升模型的实时性能,系统采用基于滑动窗口的在线学习策略。通过设置合适的时间窗口长度(本研究设置为30 min),系统在保持计算效率的

同时,可以及时捕获设备状态的动态变化。同时,引入增量学习机制,使模型能够不断从新数据中学习,提高评估的准确性。

在训练数据的构建方面,收集大量设备正常运行和各类故障状态下的历史数据。通过专家经验和数据分析,建立详细的健康度标注规则,为模型提供可靠的监督学习样本。

为验证模型的有效性,系统设置分层的健康度阈值体系。当健康度低于警戒阈值时,系统会产生预警信号;当低于危险阈值时,则触发紧急告警。阈值的设定基于大量历史数据的统计分析,并考虑设备的重要程度和维护成本等因素。

通过这种基于深度学习的实时监测机制,系统可以实现对设备健康状态的精确评估和预警,为预测性维护提供有力的技术支撑。该机制不仅可以提高状态监测的准确性和实时性,还通过智能化的特征权重分配,可以增强系统对复杂故障模式的适应能力。

关键技术分析

1. 深度学习故障识别

电气设备故障特征的多样性和复杂性对故障识别模型提出了较高要求。为此,本研究设计一种改进的深度卷积神经网络结构,通过多尺度特征提取和优化的损失函数设计,提升模型的故障识别性能。损失函数的设计为

$$L = -\sum_{i=1}^n [y_i \log(\hat{y}_i) + \beta R(w)] \quad (6)$$

式中, y_i 为真实标签; $\hat{y}_i$ 为模型预测输出; β 为正则化系数; $R(w)$ 为 L_2 正则化项。

通过引入正则化项,有效抑制了模型过拟合现象,提升了泛化能力。

为实现多尺度特征的有效提取,设计了并行的多尺度卷积结构

$$F_l = \sigma\left(\sum_{k=1}^K W_k \times X_{l-1} + b_k\right) \quad (7)$$

式中, F_l 为第 l 层的特征图; W_k 为对应的权重矩阵; $\otimes$ 表示卷积运算; K 为并行卷积分支数。

在故障识别过程中,网络采用深度可分离卷积结构,降低计算复杂度。每个卷积分支使用不同尺寸的卷积核(3×3 、 5×5 、 7×7),实现对不同尺度特征的并行提取。为增强特征的表达能力,在每

个卷积层后添加批归一化层和ReLU激活函数，解决深度网络训练过程中的梯度消失问题。

特征融合阶段采用注意力机制，对不同尺度特征进行自适应加权。通过计算特征通道间的相关性矩阵，系统能够自动学习各尺度特征的重要性权重，实现特征的动态融合。这种设计可以提升模型对局部和全局特征的综合利用能力。

为提高模型的训练效率，采用改进的学习率调度策略。在训练初期使用较大的学习率快速收敛，随后通过余弦退火方式逐步降低学习率，实现模型的精细优化。

模型的训练过程采用批量训练方式，每批数据包含多种故障类型的样本。为解决样本不平衡问题，设计基于类别权重的采样策略，确保每个批次中各类故障样本的合理分布。同时，通过数据增强技术，如添加高斯噪声、信号截断等方法，扩充少数类样本，提高模型对罕见故障的识别能力。

这种基于深度学习的故障识别方法，通过多尺度特征提取和优化的模型结构设计，实现对电气设备故障的精确识别。系统不仅可以提高故障识别的准确性，还可以通过合理的算法优化确保实时性能，为设备的智能化运维提供可靠的技术支撑。

2. 边缘计算架构

为解决传统集中式计算架构中的数据传输延迟问题，系统采用动态负载均衡的边缘计算架构

$$L_i = \frac{C_i \cdot \eta_i}{\sum_{j=1}^n C_j \cdot \eta_j} \times L_{\text{total}} \quad (8)$$

式中， L_{total} 表示t时刻的系统总体计算负载； η_i 为第i个边缘节点的效率因子； C_i 为对应节点的计算任务量。

引入节点效率因子 η_i ，实现了计算资源的动态优化分配。

3. 故障预警机制

面对电气设备状态监测中持续增长的数据处理需求，传统的集中式云计算架构在数据传输延迟和网络带宽占用等方面表现出明显的局限性。为此，本研究提出一种基于动态负载均衡的边缘计算架构，其负载分配模型可用贝叶斯公式表示为

$$P(F_t | S_t) = \frac{P(S_t | F_t)P(F_t)}{\sum_{k=1}^K P(S_t | F_k)P(F_k)} \quad (9)$$

在实际部署过程中，系统采用三层架构设计。底层为数据采集层，部署各类传感器节点；中层为边缘计算层，由多个边缘计算节点组成；顶层为云计算层，负责复杂算法的训练和全局优化。这种分层设计充分利用边缘计算的优势，实现对数据就近处理和实时响应。

节点效率因子 η_i 综合考虑了计算节点的处理能力、网络状态和能耗等多个维度，其计算公式为

$$\eta_i = \alpha \cdot \frac{P_i}{P_{\max}} + \beta \cdot \frac{B_i}{B_{\max}} + \gamma \cdot \frac{E_{\max} - E_i}{E_{\max}} \quad (10)$$

式中， P_i 为处理能力； B_i 为带宽资源； E_i 为能耗水平； α 、 β 、 γ 为权重系数。

通过动态调整效率因子，系统能够实现计算资源的最优分配。

为保证边缘计算的实时性能，系统采用任务分割和并行处理策略。大型计算任务被分解为多个子任务，并根据效率因子分配给不同的边缘节点。任务调度采用改进的蚁群算法，通过信息素更新机制动态优化任务分配方案。

数据缓存策略是确保系统稳定性的关键。每个边缘节点配备了本地缓存，采用LRU-K替换算法管理缓存数据。通过建立数据访问频率模型，系统能够预测热点数据并提前缓存，减少数据访问延迟。

为应对网络波动，系统实现故障自愈机制。当某个边缘节点失效时，相邻节点能够快速接管其任务，确保服务的连续性。通过引入心跳检测机制，系统能够及时发现节点故障并触发任务迁移流程。

在安全性方面，采用多层次的防护措施。数据传输采用TLS1.3协议加密，节点间通信使用双向认证机制。同时，实现了基于角色的访问控制，严格管理各类资源的使用权限。实验证明，该安全框架能有效防御常见的网络攻击，保障系统的安全运行。

资源调度方面，系统采用弹性伸缩策略，能够根据业务负载动态调整计算资源。通过监控CPU使用率、内存占用等指标，系统在负载超过阈值时自动启动新的计算实例，确保处理性能。

这种基于动态负载均衡的边缘计算架构，通过效率因子导向的资源调度和多层次的优化设计，实现计算资源的高效利用和系统性能的显著提升，为电气设备状态监测系统的大规模部署奠定技术基础。

应用案例与分析

1. 工程应用背景

本研究选择某220 kV智能变电站作为应用验证场所，该变电站包含2台主变压器、12个断路器以及相关的电气设备。系统部署了86个智能传感器节点，覆盖温度、振动和局部放电等关键监测参数，实现了对重要设备的全方位监测。部署周期为12个月，累计采集运行数据超过10 TB。

2. 系统实施过程

系统部署分三个阶段进行：第一阶段完成基础设施建设，包括传感器安装、通信网络搭建和边缘计算节点部署；第二阶段进行系统调试，包括数据采集校准、算法优化和模型训练；第三阶段开展实际运行验证，持续优化系统性能参数。

在边缘计算架构方面，部署了8个边缘计算节点，采用动态负载均衡策略实现计算资源的优化分配。系统采用分层存储架构，边缘节点保留近期数据，历史数据定期迁移至云端存储。

3. 应用效果分析

系统运行效果评估结果和经济效益见表1和表2。

表1 系统运行效果评估

评估指标	改进前	改进后	提升幅度
故障预警准确率	82.5%	96.8%	14.3%
平均响应时间	180 ms	45 ms	75.0%
故障预警提前量	24 h	72 h	200.0%
误报率	8.5%	2.1%	75.3%
数据处理效率	2.8 GB/s	8.5 GB/s	203.6%
系统可用性	95.2%	99.8%	4.6%

通过对比可知，系统运行效果显著超出预期，各项性能指标均取得明显提升。故障预警准确率从原来的82.5%提升至96.8%，平均响应时间从180 ms降低到45 ms，故障预警提前量从24 h延长至72 h，误报率从8.5%下降到2.1%，数据处理效率从2.8 GB/s提升至8.5 GB/s，系统可用性从95.2%提高到99.8%。这些指标的显著改善充分证明系统设计的先进性和实用性。

表2 经济效益

成本项目	年度节省/万元	节省比例 (%)
维护人工成本	85.6	42.3
备品备件成本	67.2	35.8
停电损失	156.4	68.5
设备更换成本	234.8	45.2

从经济效益角度分析，系统的部署为变电站带来了显著的成本节省。维护人工成本年度节省85.6万元，降低42.3%；备品备件成本节省67.2万元，降低35.8%；停电损失减少156.4万元，降低68.5%；设备更换成本节省234.8万元，降低45.2%。这些数据充分证明系统在经济性方面的优势。

结束语

综上所述，基于边缘计算和深度学习技术的电气设备智能监测系统，通过多源数据实时融合与智能算法的深度应用，显著提升设备状态监测的准确性和实时性。结合创新的边缘计算架构与改进的深度学习模型，系统实现故障预警准确率提升至96.8%，平均响应时间降低至45 ms的突出性能。本研究提出的监测方案在提升电力设备运维效率和预测性维护能力方面具有显著优势，年度维护成本降低48.2%，为智能变电站的数字化转型提供了理论依据和实践指导。

研究成果不仅解决传统监测系统存在的数据处理延迟、故障预警不准确等技术难题，还通过边缘计算架构的优化设计，实现计算资源的高效利用和系统性能的显著提升。特别是在复杂工况下的设备状态评估和故障发展趋势预测方面，系统表现出优异的泛化能力和抗干扰性，为电力设备的安全稳定运行提供可靠保障。EA

(收稿日期：2024-11-08)

参考文献

[1] 宋元军, 强盛. 基于人工智能的高压电气设备故障诊断与预防系统设计与实现[J]. 电气技术与经济, 2024(12): 115-117.

[2] 刘军强. 人工智能在电气设备故障诊断中的应用[J]. 自动化应用, 2023, 64(7): 1-3+6.

[3] 吕杰. 电气自动化系统中的故障诊断与智能监控策略研究[J]. 中国仪器仪表, 2025(1): 44-47.

[4] 罗傑琼. 人工智能在自动化变电站保护系统故障诊断与评估中的应用[J]. 光源与照明, 2024(12): 80-82.

[5] 孙振超, 王路, 孙国青. 人工智能在电力通信系统故障诊断与预测分析[J]. 家电维修, 2025(1): 68-70.