

人工智能驱动的电气设备状态监测与寿命预测模型构建

姬广辉

南水北调中线信息科技有限公司

DOI:10.32629/btr.v8i8.4961

[摘要] 随着新型电力系统建设的加速推进和“双碳”战略目标的深入实施,电网设备的安全、稳定、高效运行已成为保障能源安全的关键。传统的电气设备运维模式多依赖定期检修或事后维修,存在成本高、效率低、故障预警能力弱等固有缺陷。在此背景下,以人工智能(AI)为核心驱动力的状态监测与寿命预测技术应运而生,为实现设备全生命周期的智能化管理提供了全新范式。本文系统性地探讨了人工智能在电气设备状态监测与寿命预测领域的应用框架。首先,分析了当前电气设备运维面临的挑战,并阐述了AI技术介入的必要性;其次,详细梳理了数据采集、特征工程、模型构建等关键环节的技术路径;再次,重点构建了一种融合深度学习与物理机理的混合寿命预测模型,并对其核心算法进行了深入剖析。研究表明,AI驱动的智能诊断与预测体系能够显著提升设备状态评估的准确性与前瞻性,为构建新一代智能运维体系奠定坚实的技术基础。

[关键词] 人工智能; 电气设备; 状态监测; 寿命预测; 深度学习; 智能运维

中图分类号: TM76 **文献标识码:** A

AI-Driven Condition Monitoring and Life Prediction Model Construction for Electrical Equipment Guanghui Ji

South-to-North Water Diversion Middle Route Information Technology Co., Ltd.

[Abstract] With the accelerated construction of new power systems and the in-depth implementation of the "dual carbon" strategic goals, the safe, stable, and efficient operation of power grid equipment has become key to ensuring energy security. Traditional electrical equipment operation and maintenance models mostly rely on periodic inspection or post-fault repair, which have inherent defects such as high cost, low efficiency, and weak fault warning capability. Against this background, condition monitoring and life prediction technology driven by artificial intelligence (AI) has emerged, providing a new paradigm for intelligent management of equipment throughout its entire life cycle. This paper systematically explores the application framework of artificial intelligence in the field of electrical equipment condition monitoring and life prediction. First, it analyzes the challenges currently faced in electrical equipment operation and maintenance, and expounds on the necessity of AI technology intervention. Second, it details the technical paths of key steps such as data acquisition, feature engineering, and model construction. Third, it focuses on constructing a hybrid life prediction model that integrates deep learning and physical mechanisms, and deeply analyzes its core algorithms. Research shows that AI-driven intelligent diagnosis and prediction systems can significantly improve the accuracy and foresight of equipment condition assessment, laying a solid technical foundation for building a new generation of intelligent operation and maintenance systems.

[Key words] artificial intelligence; electrical equipment; condition monitoring; life prediction; deep learning; intelligent operation and maintenance

引言

电气设备是电力系统的核心,其健康状况关乎电网安全、可靠与经济性。关键设备故障不仅会造成经济损失,还可能引发大

面积停电。因此,科学掌握设备实时运行状态并精准预测剩余寿命,是电力行业长期核心课题。传统设备维护策略包括定期检修与事后维修,但前者可能导致“过度维护”,无法预防突发故障;

后者属被动响应, 损失难挽回。为此, 以状态为基础的维护理念被提出, 但其高度依赖设备状态信息的全面感知与精准解读。现代电气设备结构复杂, 劣化受多因素耦合影响, 传统信号处理与浅层机器学习模型难充分挖掘数据规律, 导致状态评估与寿命预测精度有限^[1]。近年来, 深度学习等人工智能技术取得突破, 为解决此问题提供新工具。本文旨在构建AI驱动框架, 用于电气设备状态监测与寿命预测。

1 相关工作与技术背景

1.1 电气设备状态监测技术演进

电气设备状态监测技术经历了从离线到在线、从单一参量到多参量融合的发展历程。早期主要依赖离线试验, 如绝缘电阻测试、介质损耗因数($\tan\delta$)测量等。随着传感器技术和通信技术的发展, 在线监测系统得以广泛应用, 常见的监测参量包括: (1) 油中溶解气体分析(DGA): 被誉为变压器的“血液检测”, 通过分析绝缘油中 H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6 等特征气体的含量及增长速率, 可有效判断内部是否存在过热、放电等潜伏性故障。(2) 局部放电(PD)检测: 捕捉设备绝缘系统中的微弱放电信号, 是评估绝缘老化程度的关键手段。(3) 振动与声学监测: 用于监测机械部件(如变压器铁芯、冷却风扇)的松动、磨损等异常。(4) 红外热成像: 非接触式地获取设备表面温度场分布, 快速定位过热点。尽管监测手段日益丰富, 但如何将这些多源异构数据有效融合, 并从中提炼出具有明确物理意义的健康指标(Health Index, HI), 仍是巨大挑战。

1.2 寿命预测模型研究现状

寿命预测模型大致可分为三类: (1) 基于物理/经验模型的方法: 如Arrhenius方程(用于描述温度对绝缘材料老化的影响)、Montsinger模型等。这类模型物理意义清晰, 但通常需要大量先验知识和精确的边界条件, 且难以适应复杂的实际运行工况。(2) 基于数据驱动的方法: 利用历史数据建立输入(监测数据)与输出(RUL)之间的映射关系。早期主要采用回归分析、灰色预测等方法。近年来, 机器学习方法成为主流, 如利用SVM进行分类以判断设备健康等级, 或利用回归树预测RUL^[2]。(3) 混合模型: 试图结合物理模型的可解释性与数据驱动模型的自适应性。例如, 将物理模型的输出作为数据驱动模型的输入特征之一, 或利用数据驱动方法对物理模型的参数进行在线修正。当前研究趋势表明, 纯粹的数据驱动模型虽然在特定场景下表现优异, 但其“黑箱”特性限制了其在高可靠性要求的电力系统中的可信度。因此, 构建兼具高精度与强可解释性的混合模型是未来的重要方向。

1.3 人工智能在电力设备领域的应用

深度学习, 特别是循环神经网络(RNN)及其变体长短期记忆网络(LSTM)、门控循环单元(GRU), 因其擅长处理时间序列数据, 在设备RUL预测中得到广泛应用。卷积神经网络(CNN)则被用于从振动信号、局部放电图谱等一维或二维信号中自动提取空间或频域特征。此外, 自编码器(Autoencoder)可用于无监督的异常检测, 而强化学习则为最优维护决策提供了新思路。然而, 现

有研究大多聚焦于单一数据源或单一模型的应用, 缺乏一个系统性的、能够整合多源信息并融合领域知识的通用框架。本文正是针对这一空白展开研究。

2 AI驱动的状态监测与寿命预测系统架构

为实现高效的智能运维, 可以构建一个四层递进式的AI驱动系统架构。该架构以全面感知为基础, 以智能分析为核心, 以决策支持为出口, 形成了一个完整的数据价值闭环。

2.1 第一层: 多源数据感知层

最底层是多源数据感知层, 它作为整个系统的基石, 负责全面、实时地采集设备运行状态数据。这些数据来源极为广泛, 既包括来自在线监测系统的连续DGA数据、局部放电量、温度、振动等动态信息, 也涵盖定期预防性试验产生的离线数据, 如绕组变形、绝缘电阻等; 同时, 来自SCADA系统的负荷电流、电压等运行工况数据, 以及温湿度、污秽度等环境数据, 乃至设备制造商、投运日期、检修记录等静态台账信息, 都被统一纳入感知范畴。所有异构数据通过物联网(IoT)网关进行汇聚, 并完成初步的清洗、时间对齐和标准化处理, 为上层分析提供高质量的数据原料。

2.2 第二层: 特征工程与健康指标构建层

原始监测数据通常包含大量噪声、冗余甚至缺失值, 直接用于建模不仅效率低下, 而且效果不佳。因此, 本层的核心任务是对原始数据进行深度加工, 提炼出对设备健康状态最具判别力的信息。这一过程首先涉及特征提取, 例如, 对于DGA数据, 不仅要使用各气体的绝对浓度, 还需计算总烃、产气速率以及IEC三比值等衍生特征; 对于振动信号, 则需从时域、频域以及时频域等多个维度提取统计特征^[3]。随后, 通过相关性分析、主成分分析(PCA)或基于模型的特征重要性评估等方法, 筛选出一个精简而有效的特征子集。最终, 将这些多维特征融合为一个或少数几个能够综合表征设备整体健康水平的健康指标(Health Index, HI)。HI的构建既可以基于专家经验规则进行加权求和, 也可以通过无监督学习方法(如聚类)从数据中自动发现潜在的健康状态模式。

2.3 第三层: AI核心模型层

这是系统的核心智能引擎, 该层包含两大功能模块, 共同构成系统的“大脑”。状态监测与故障诊断模块负责对当前时刻的设备状态进行实时研判, 它通常采用分类模型(如CNN-LSTM)对当前的HI序列或原始特征序列进行分析, 不仅能判断设备处于正常、预警还是故障状态, 还能进一步识别具体的故障类型, 如过热、电弧放电或绝缘受潮等。寿命预测模块则着眼于未来, 它基于历史HI序列或关键特征序列, 利用回归模型预测设备健康状态的演化轨迹, 并据此估算出剩余使用寿命(RUL)。这两个模块相辅相成, 前者为后者提供准确的当前状态起点, 后者则为前者提供前瞻性的风险预警。

2.4 第四层: 决策支持与可视化层

最顶层是决策支持与可视化层, 其作用是将AI模型输出的抽象结果转化为直观、可操作的运维指令。通过可视化大屏,

运维人员可以一目了然地查看设备的实时健康状态、RUL预测曲线、风险等级分布等关键信息。系统还能根据预设的业务规则，当预测RUL低于安全阈值或健康状态进入预警区时，自动触发维护工单，并通过移动终端推送给相关责任人，从而实现了从“数据感知”到“智能分析”再到“主动决策”的完整闭环管理。

3 融合深度学习与物理机理的混合寿命预测模型

为兼顾预测精度与模型可解释性，本文提出一种名为“Physics-Informed Deep Learning for RUL Prediction (PIDL-RUL)”的混合模型。其核心思想是：利用深度学习强大的非线性拟合能力捕捉数据中的复杂模式，同时将已知的物理退化规律作为软约束嵌入到模型训练过程中，引导模型学习符合物理常识的退化轨迹。

3.1 模型总体架构

PIDL-RUL模型由两个主要分支构成：

3.1.1 数据驱动分支

主体是一个双向LSTM(Bi-LSTM)网络。Bi-LSTM能够同时利用过去和未来的上下文信息(在训练阶段，未来信息指历史数据中当前时刻之后的部分)，从而更全面地理解设备的健康状态演变。输入为经过特征工程处理后的多维时间序列特征 $X = \{x_1, x_2, \dots, x_t\}$ ，输出为设备在每个时刻 t 的隐含健康状态表示 h_t 。

3.1.2 物理约束分支

该分支不直接参与前向计算，而是在损失函数中引入一个物理正则项。我们选取经典的Arrhenius老化模型作为物理先验。该模型指出，绝缘材料的老化速率与绝对温度呈指数关系。我们将在线监测的顶层油温 $T(t)$ 代入Arrhenius方程，计算出理论上的累积老化因子 $A_{phys}(t)$ 。

3.2 损失函数设计

模型的总损失函数 \mathcal{L}_{total} 由两部分组成：

$$\mathcal{L}_{total} = \mathcal{L}_{data} + \lambda \mathcal{L}_{physics}$$

数据损失项 \mathcal{L}_{data} ：衡量模型预测的RUL与真实RUL之间的误差。考虑到RUL预测是一个回归问题，我们采用平滑的L1损失(Huber Loss)以降低异常值的影响。

$$\mathcal{L}_{data} = \frac{1}{N} \sum_{i=1}^N \text{Huber}(RUL_i^{pred}, RUL_i^{true})$$

物理损失项 $\mathcal{L}_{physics}$ ：强制数据驱动分支学习到的健康状态 h_t 的变化趋势与物理模型计算出的老化因子 $A_{phys}(t)$ 的变化趋势保持一致。具体地，我们计算两者的一阶导数(即变化率)

之间的均方误差(MSE)。

$$\mathcal{L}_{physics} = \text{MSE} \left(\frac{dh_t}{dt}, \frac{dA_{phys}(t)}{dt} \right)$$

其中，导数可通过数值微分(如中心差分法)近似计算。超参数 λ 用于平衡两项损失的权重。

通过这种设计，即使在某些时段监测数据质量不佳或缺失，模型也能在物理规律的约束下做出相对合理的推断，从而提高了模型的鲁棒性和泛化能力。

3.3 健康指标到RUL的映射

Bi-LSTM输出的健康状态序列表征了设备从健康到失效的全过程。我们定义当健康状态 h_t 下降到某个预设的失效阈值 h_c 时，设备寿命终结^[4]。RUL的预测即转化为预测从当前时刻 t_c 到 $h_t=h_c$ 所需的时间步长。这可以通过在LSTM顶部增加一个全连接层直接回归RUL，或者采用更精细的序列到序列(Seq2Seq)方式预测未来的健康状态轨迹，再从中反推RUL。

4 结语

本文聚焦“人工智能驱动的电气设备状态监测与寿命预测”，构建系统性技术框架，创新提出融合深度学习与物理机理的混合寿命预测模型(PIDL-RUL)，经理论分析得出结论：AI是智能运维关键，能处理监测数据特性，助力精准评估与预测；混合模型优势明显，融入领域知识可提升预测精度等，更适配电力场景；多源数据融合对构建全面设备健康画像至关重要。展望未来，研究可在多方向深化：引入贝叶斯神经网络等方法实现不确定性量化，为运维决策提供风险参考；利用迁移学习等技术解决新设备小样本与零样本学习难题；将AI模型嵌入数字孪生体，实现物理与虚拟交互协同，推动从“预测性维护”到“自主健康管理”的跨越。

[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]张君.基于人工智能的电气设备智能维护系统设计研究[J].电气技术与经济,2025(5):125-127,130.
- [3]王柯杰.基于人工智能的电气设备维修预测分析[J].软件,2024,45(10):93-95.
- [4]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.