

# 设备在线监测与数据分析在电力系统中的应用研究

秦艳 谷聚辉 余晓 傲东

国网新疆电力有限公司昌吉供电公司，新疆昌吉，831100；

**摘要：**电力系统依赖电力设备的稳定运行，但传统设备管理方式已不能满足智能电网的需求。本文提出在线监测与数据分析技术，作为实现预测性维护的核心，详细介绍了系统架构和关键技术。通过研究大数据和AI在数据分析中的应用，并以变压器故障诊断为例，实验证明智能诊断模型的性能优于传统方法。文章最后展望了数字孪生和边缘计算等技术在设备监测中的融合趋势。

**关键词：**在线监测；状态检修；预测性维护；大数据分析；人工智能；故障诊断；电力变压器

**DOI：**10.69979/3060-8767.25.11.007

## 引言

电力工业是国民经济的命脉，其安全稳定运行直接关系到国家能源安全与社会发展。发电厂、变电站、输电线路中的各类电力设备作为电网的物理载体，其健康状态是电网可靠性的决定性因素。长期以来，电力系统主要采用“定期检修”和“故障后维修”为主的设备维护策略。定期检修存在过度维修导致资源浪费，或检修周期内发生故障的风险；事后维修则被动响应，停电损失大，可能引发连锁故障<sup>[1]</sup>。

随着智能电网和新型电力系统建设的深入推进，电网结构日益复杂，设备数量激增，对供电可靠性的要求达到了前所未有的高度。在此背景下，以状态监测为基础的预测性维护模式成为必然选择。设备在线监测技术通过安装在设备上的各类传感器，持续、实时地采集能反映其健康状态的多种物理、化学量，并借助现代通信技术将数据上传至数据中心。然而，海量的监测数据本身并不能直接产生价值，必须通过先进的数据分析技术，从中提取有效信息、识别潜在故障、预测剩余寿命，才能最终形成科学的运维决策。

因此，本研究旨在深入探讨设备在线监测与数据分析技术在电力系统中的综合应用。首先构建在线监测的系统框架，继而系统分析数据处理与分析的关键技术路径，并通过针对变压器故障诊断的对比实验，实证数据分析技术的巨大潜力，以期为电力企业的设备资产管理数字化转型提供理论依据和实践参考<sup>[2]</sup>。

## 1 设备在线监测系统架构与关键技术

### 1.1 系统架构

一个完整的设备在线监测系统通常采用分层分布式架构，自下而上可分为感知层、传输层、平台层和应用层。

感知层：由部署在设备上的各类传感器和采集单元构成，是系统的“神经末梢”。负责采集如变压器油中

溶解气体、绕组温度、局部放电信号；断路器的机械特性、分合闸线圈电流；电缆接头温度、护层接地电流等状态量。

传输层：负责将感知层采集的数据安全、可靠地传输到数据平台。可采用有线或无线通信方式，根据现场环境和实时性要求进行选择。

平台层：是系统的“大脑”，通常基于云平台或大数据平台构建。负责海量监测数据的接收、存储、管理和处理。提供数据仓库、计算引擎、模型管理等功能，为上层应用提供支撑。

应用层：面向运维人员，提供数据可视化、状态评估、故障预警、诊断分析、运维决策支持等功能，最终以图形化界面、报表、移动端告警等形式呈现。

### 1.2 关键监测技术

针对不同类型的电力设备，在线监测技术各有侧重，以确保电网的稳定运行。对于变压器，监测技术主要涉及油中溶解气体分析、局部放电监测、绕组光纤测温和振动噪声分析，以评估内部状况和早期故障迹象。GIS/GIL设备的监测则集中于局部放电监测、SF6气体密度与微水监测以及振动监测，以预防绝缘故障。电缆线路的监测技术包括分布式光纤测温、局部放电监测和护层接地电流监测，以实时监控线路状态。架空线路的监测采用视频监控、微气象监测、导线弧垂与温度监测以及绝缘子污秽监测，这些技术共同确保架空线路在复杂环境中的安全运行。这些多样化的在线监测技术为电力系统的实时监控和故障预测提供了可靠的数据支持，是智能电网不可或缺的部分<sup>[3]</sup>。

## 2 监测数据分析的关键技术路径

从原始数据到运维决策，需要经过一系列数据处理与分析流程，其核心技术路径如下：

### 2.1 数据预处理

在电力设备在线监测中，原始监测数据的质量直接

影响后续分析和处理的准确性。因此，数据预处理是关键步骤，它涉及数据清洗、数据填补和数据规范化/标准化等多个环节。数据清洗过程中，需识别并处理异常值，剔除明显错误的数据，以保证数据的准确性。对于数据填补，当传感器故障或通信中断导致数据缺失时，通过插值、回归或基于时间序列的预测方法进行填补，恢复数据的完整性。此外，数据规范化/标准化是为了解决不同量纲和量级数据带来的问题，将它们转换到同一尺度，消除特征间的支配关系，从而为后续的数据分析和模型处理创造条件，提高模型的训练效率和预测的准确性。这些预处理步骤共同确保了监测数据的质量，为智能电网的稳定运行提供了坚实基础<sup>[4]</sup>。

## 2.2 特征提取与选择

在电力设备监测中，直接由传感器采集的数据通常具有高维度和信息冗余的特点，因此，特征提取环节至关重要，其目标是从原始数据中提炼出能够最有效反映设备状态变化和与故障类型密切相关的低维特征集。时域/频域分析是常用的方法，通过提取如有效值、峰值、峭度、频谱特征等，能够捕捉到振动、局部放电等信号的关键特性。同时，基于深度学习的特征自动提取技术，如自动编码器和一维卷积神经网络，可以直接从原始信号中自动学习出高层次的抽象特征，这种方法减少了对专业领域知识的依赖，提高了特征提取的效率和准确性。这些特征提取技术为电力设备状态的准确评估和故障诊断提供了有力支持，是智能电网监测系统中的关键组成部分。

## 2.3 状态评估与故障诊断

数据分析环节是判断电力设备健康状况和识别故障类型的关键步骤。传统方法如改良电桥法、三比值法和大卫三角形法等，主要基于物理化学原理和阈值判断，操作简单直观，但在处理复合故障和早期故障时，其精度和敏感性有限。随着技术的发展，智能诊断方法应运而生。机器学习模型如支持向量机、随机森林和梯度提升决策树通过有监督学习构建特征向量到故障类型的映射，提高了故障诊断的准确性。而深度学习模型，如卷积神经网络和循环神经网络，在处理图像、信号和时间序列数据方面表现出色，它们能够自动学习数据中的复杂非线性关系，从而实现更高精度的故障诊断。这些智能方法的应用，大大提升了电力设备状态监测和故障诊断的效率和准确性。

诊断方法	准确率	平均精确率	平均召回率	平均 F1-Score
IEC 三比值法（对照组）	76.30%	0.71	0.7	0.7
SVM 模型（实验组 1）	89.50%	0.88	0.87	0.87
1D-CNN 模型（实验组 2）	93.00%	0.92	0.92	0.92

详细分析：

## 2.4 故障预测与健康管理

这是在线监测的终极目标，即预测设备未来的状态趋势和剩余使用寿命。

趋势预测：利用时间序列预测模型对关键状态参量的未来走势进行预测。

剩余寿命预测：结合设备退化模型和数据驱动方法，估算设备从当前状态运行到失效状态的时间。常用方法包括维纳过程、伽马过程以及基于深度学习的生存分析模型。

## 3 实验分析：基于 DGA 的变压器故障智能诊断

为验证智能数据分析方法相较于传统方法的优越性，本节设计一个针对变压器故障诊断的对比实验。

### 3.1 实验数据与预处理

数据来源：实验数据来源于某电网公司变压器状态检修数据库，包含超过 500 台变压器的 DGA 历史数据记录及对应的吊芯检修结论。每条记录包含 H<sub>2</sub>, CH<sub>4</sub>, C<sub>2</sub>H<sub>6</sub>, C<sub>2</sub>H<sub>4</sub>, C<sub>2</sub>H<sub>2</sub>, CO, CO<sub>2</sub> 七种特征气体的含量，以及一个由专家确定的故障标签。

数据预处理：对气体含量进行归一化处理，并剔除明显不合理的数据记录。最终筛选出 380 条有效、标签明确的样本，按 7: 3 的比例随机划分为训练集和测试集。

### 3.2 实验方案与模型构建

设计三组对比实验：

(1) 对照组：采用 IEC 三比值法。根据 C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub>, CH<sub>4</sub>/H<sub>2</sub>, C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub> 三个比值的编码范围，对照标准查表进行诊断。

(2) 实验组 1：采用支持向量机模型。以 7 种气体含量作为输入特征，采用径向基函数作为核函数，使用网格搜索和交叉验证对惩罚参数 C 和核函数参数 γ 进行优化。

(3) 实验组 2：采用一维卷积神经网络模型。模型结构包括两个卷积层、两个池化层和两个全连接层。输入为 7 维的气体含量向量。

评价指标：使用准确率、精确率、召回率和 F1-Score 作为模型性能的综合评价指标。

### 3.3 实验结果与分析

三种方法在测试集上的性能对比如下表所示：

(1) 传统三比值法的局限性：三比值法取得了 76.

3%的准确率，表明其具有一定的诊断价值。但其错误主要源于：a) 比值编码区间存在边界模糊性；b) 对不属于标准编码范围的“无编码”情况无法处理；c) 无法有效利用7种气体的全部信息，诊断逻辑相对僵化。

(2) SVM模型的优势：SVM模型将准确率提升至89.5%，各项指标均有显著改善。SVM通过核函数将低维非线性问题映射到高维线性空间，能够更好地学习气体含量与故障类型之间的复杂映射关系。它同时考虑了所有特征气体，比三比值法利用了更多信息。

(3) 1D-CNN模型的卓越性能：CNN模型取得了最佳性能，准确率达到93.0%。CNN的优势在于其自动特征学习能力。卷积层能够自动从7种气体的组合中学习到比人为设定的比值更为精细、判别性更强的特征模式。这使得CNN对噪声和数据波动具有更好的鲁棒性，尤其擅长处理那些特征不明显或存在多种故障并发迹象的复杂案例。

(4) 混淆矩阵分析：进一步观察CNN模型的混淆矩阵发现，其误判主要集中在“低温过热”与“中高温过热”之间，以及“局部放电”与“低能放电”之间。这表明模型能够准确区分大类的故障，但对过热程度和放电能量等级的细分上仍有提升空间，这可能需要更丰富的样本或引入更多维度的状态量来进一步改善。

实验结论：本实验充分证明，基于人工智能的数据分析方法在变压器DGA故障诊断任务中，无论在诊断准确率还是综合性指标上，都显著优于基于经验规则的传统三比值法。其中，具备自动特征提取能力的深度学习模型表现最优，展现了大数据驱动下设备状态精准评估的巨大潜力。

#### 4 挑战与展望

虽然设备在线监测与数据分析技术在近年来取得了显著的进步，但在实际的大规模应用中，我们仍然面临着一系列挑战。首先，数据质量和标注问题成为制约监督学习模型性能的瓶颈，监测数据往往噪声较大，而且带有精确故障标签的样本相对稀缺，这限制了模型的训练效果和泛化能力。其次，模型的可解释性问题也日益凸显，尤其是深度学习模型由于其复杂性和抽象性，往往被视为“黑箱”，决策过程难以解释，这在一定程度上影响了运维人员对诊断结果的信任和采纳。此外，信息孤岛问题也亟需解决，不同设备、不同系统的监测数据尚未实现完全的互联互通，这限制了跨设备的协同分析和数据价值的最大化。

未来技术发展呈现出几个明显趋势。首先，与数字孪生技术的深度融合将成为一个重要方向，通过构建与物理设备实时同步的数字孪生体，我们可以在虚拟空间中进行状态推演、故障模拟和预测性维护方案的验证，

实现更深层次的智能化。其次，边缘智能的发展将使得轻量化的AI模型能够部署在边缘侧，实现数据的就地处理和实时诊断，这不仅可以减轻云端的压力，还能够满足实时响应的需求。再者，跨模态融合分析将成为提升设备健康评估全面性的关键，通过融合DGA、局放、振动、红外热像等多模态监测数据，并结合设备台账、运维历史、环境信息等，我们可以进行全方位、立体化的健康评估。最后，针对数据标注样本稀缺的问题，小样本学习和迁移学习的研究将成为解决样本依赖瓶颈的有效途径，通过这些算法的研究和应用，我们有望在数据不足的情况下，仍然实现有效的模型训练和故障诊断。

#### 5 结论

设备在线监测与数据分析是电力系统运维模式向智能化、精准化转型的核心驱动力。本文系统性地梳理了该技术的体系架构、分析流程和关键算法。通过以变压器DGA故障诊断为案例的对比实验，实证了人工智能方法相较于传统方法的显著优势。面对未来新型电力系统的更高要求，推动监测技术与大数据、人工智能、数字孪生等前沿技术的更深度融合，解决数据质量、模型可信度等实际挑战，将是实现电力设备“全息感知、精准诊断、预测预警、主动运维”的必由之路，对保障大电网安全、提升运营效益具有至关重要的意义。

#### 参考文献

- [1] 王刘芳, 李卫国, 廖瑞金, 等. 基于深度置信网络的变压器故障诊断方法[J]. 中国电机工程学报, 2015, 35(10): 2587-2594.
- [2] 董明, 文劲宇, 张哲, 等. 电力设备状态大数据分析的研究现状与发展趋势[J]. 高电压技术, 2018, 44(4): 1041-1050.
- [3] 李化, 林福昌, 何俊佳. 电力设备状态监测与故障诊断技术[M]. 北京: 中国电力出版社, 2017.
- [4] IEEE Standard for Condition-Based Maintenance of Power Equipment. IEEE Std C57.143-2012.
- [5] SiXS, WangWB, HuCH, et al. Remaining useful life estimation-A review on the statistical data driven approaches[J]. European Journal of Operational Research, 2011, 213(1): 1-14.

作者简介：秦艳，出生年月：1992年9月，性别：女，籍贯到市：新疆呼图壁县，民族：汉，学历：大学本科，职称：中级工程师，研究方向：变电站运行维护、继电保护及自控装置运维、故障应急处置、智能电网分析与研究。