

基于深度学习的电力设备故障诊断研究

吴志毅 140602198402281718

摘要

电力设备是电力系统稳定运行的核心载体，其运行状态直接关系到整个电网的供电可靠性与安全性。传统电力设备故障诊断方法依赖人工提取特征，对复杂隐性故障的识别精度较低，难以适配当前电网设备规模化、复杂化的发展趋势。深度学习技术凭借自动特征提取、非线性模式识别的优势，为电力设备故障诊断提供了新的技术路径。本文梳理了基于深度学习的电力设备故障诊断研究现状，分析了卷积神经网络、循环神经网络、深度置信网络等典型模型在不同类型电力设备故障诊断中的应用逻辑，探讨了当前研究存在的数据样本不平衡、小样本故障识别精度不足、模型可解释性差等问题，最后对未来的研究方向进行了展望，为推动深度学习技术在电力设备故障诊断领域的落地应用提供参考。

关键词：深度学习；电力设备；故障诊断；特征提取

一、引言

随着我国电网建设规模持续扩大，特高压输电工程、新能源并网项目不断推进，电力系统中变压器、断路器、高压开关柜等核心电力设备的运行压力也逐步提升。电力设备长期处于高电压、强电流、温湿度变化复杂的运行环境中，绝缘老化、机械磨损等问题会逐步累积，若不能及时诊断出早期故障，极有可能引发大规模停电事故，造成巨大的经济损失与社会影响。因此，高效准确的电力设备故障诊断技术是保障电网安全稳定运行的关键支撑。

传统的电力设备故障诊断方法主要包括基于解析模型的方法与基于信号处理的方法，其中基于解析模型的方法需要建立精准的设备物理模型，而电力设备结构复杂、故障诱因多样，难以构建通用的精确模型；基于信号处理的方法需要依赖专业技术人员人工提取振动、局部放电等信号的故障特征，对人员经验要求较高，且对于早期隐性故障的特征提取精度不足，漏诊、误诊问题较为突出。近年来，传感技术与大数据存储技术快速发展，电力设备运行过程中积累了海量的状态监测数据，为深度学习技术的应用奠定了数据基础。深度学习通过多层神经网络自动从原始监测数据中挖掘故障特征，无需人工干预，能够有效识别复杂的故障模式，显著提升故障诊断的精度与效率，因此成为电力设备故障诊断领域的研究热点。

二、深度学习在电力设备故障诊断中的典型应用模型

2.1 卷积神经网络（CNN）

卷积神经网络是目前电力设备故障诊断领域应用最为广泛的深度学习模型，其通过局部感受野、权值共享与池化操作三个核心结构，有效降低了模型的参数规模，同时能够自动提取输入数据的空间特征。对于变压器、发电机等旋转或非旋转电力设备，通过将采集到的一维振动信号、局部放电信号转换为二维时频图后，卷积神经网络能够精准提取不同故障类型的特征差异，实现故障分类。

现有研究中，已有大量学者将卷积神经网络应用于变压器局部放电故障诊断，通过对超声波、超高频局部放电信号进行预处理后输入 CNN 模型，故障识别精度可达 95%以上，远高于传统的支持向量机等方法。针对高压断路器的机械故障诊断，研究人员将振动信号转换为灰度图输入 CNN 模型，能够准确识别拒动、误动等不同类型的机械故障，即使在强噪声环境下依然保持较高的诊断精度。

2.2 循环神经网络（RNN）及其改进模型

循环神经网络擅长处理具有时间序列特性的数据，电力设备的状态监测数据大多是随时间连续采集的序列数据，故障的发展也是一个动态演化的过程，因此 RNN 及其改进模型长短时记忆网络（LSTM）非常适用于电力设备的渐变故障诊断与早期故障预测。LSTM 通过输入门、遗忘门与输出门的结构设计，解决了传统 RNN 存在的梯度消失问题，能够捕捉长时间序列数据中的依赖关系，精准识别故障发展的趋势。

在实际应用中，LSTM 常被用于电力变压器的油中溶解气体分析，通过分析不同时间节点的气体浓度变化序列，预测绝缘故障的发展趋势，实现早期故障预警。针对输电线路的覆冰故障，研究人员通过 LSTM 模型分析气象与线路状态的时间序列数据，能够提前数天预测覆冰故障的发生，为运维人员采取融冰措施争取时间。

2.3 深度置信网络（DBN）

深度置信网络是由多个受限玻尔兹曼机堆叠形成的深度生成模型，能够通过无监督预训练与有监督微调两个阶段完成特征提取与故障分类，在小样本数据集上具有较好的表现。深度置信网络可以直接从原始监测数据中提取抽象特征，不需要复杂的信号预处理过程，简化了故障诊断的流程。在电力设备故障诊断中，深度置信网络常被用于小样本故障的识别，针对部分故障类型样本数量少的问题，

通过无监督预训练充分挖掘未标注样本中的信息，提升模型的泛化能力。

三、当前研究存在的主要问题

尽管基于深度学习的电力设备故障诊断已经取得了诸多研究成果，但距离大规模工程落地依然存在不少需要解决的问题。首先是故障数据样本不平衡问题，电力设备正常运行时间远长于故障运行时间，收集到的故障样本尤其是罕见故障样本数量非常少，多数深度学习模型在不平衡数据集上训练后会偏向多数类样本，导致小样本故障的识别精度极低。其次是模型的可解释性不足，深度学习模型本质上是黑箱模型，模型输出故障诊断结果后，无法清晰说明诊断的依据，电力系统运行对安全性要求极高，运维人员难以完全信任无解释的诊断结果，阻碍了技术的推广应用。第三是模型的泛化能力不足，多数现有模型都是针对特定型号、特定场景下的电力设备训练得到的，当设备运行环境发生变化或者更换设备型号后，模型的诊断精度会大幅下降，难以适配不同场景的应用需求。

四、未来研究方向展望

针对当前研究存在的问题，未来基于深度学习的电力设备故障诊断可以从几个方向推进研究：一是小样本与零样本故障诊断技术的研究，通过生成对抗网络合成故障样本、迁移学习预训练等方法，解决小样本故障识别精度不足的问题；二是可解释深度学习故障诊断模型的研究，通过引入注意力机制、知识蒸馏等方法，提升模型诊断结果的可解释性，让运维人员能够清晰了解诊断依据，提升技术接受度；三是边缘深度学习故障诊断技术的研究，将深度学习模型部署在边缘终端设备上，实现故障诊断的本地化处理，降低数据传输带宽需求，提升诊断的实时性，适配智能电网的发展需求。

五、结论

基于深度学习的电力设备故障诊断技术突破了传统故障诊断方法依赖人工提取特征的局限，能够充分利用电力设备积累的海量状态监测数据，显著提升故障诊断的精度与效率，是未来电力设备运维技术的重要发展方向。当前该领域的研究已经取得了显著进展，但在小样本故障识别、模型可解释性等方面依然存在不足，需要进一步深入研究，推动技术的工程落地，为我国电网的安全稳定运行提供更有力的技术支撑。

参考文献

- [1] 赵淳, 阮江军, 龚政雄, 等. 深度学习在电力设备故障诊断中的应用研究综述[J]. 中国电机工程学报, 2020, 40(12): 3876-3890.
- [2] 王金玉, 李卫国, 汪可. 基于卷积神经网络的变压器局部放电故障诊断方法[J]. 电工技术学报, 2019, 34(10): 2183-2192.
- [3] 张宏, 王健, 刘新. 基于长短时记忆网络的电力变压器早期绝缘故障预测[J]. 电力系统自动化, 2021, 45(5): 123-130.