

基于深度学习的轨道交通供电设备故障预测方法

吴 炼 李瑞梅 林建华

绍兴市轨道交通集团有限公司运营分公司 浙江 绍兴 312000

摘要: 随着运营里程增加与设备服役年限增长,传统基于规则或经验的故障预测方法,因难以捕捉设备复杂非线性运行特性及潜在故障模式,已难以满足高可靠性要求。本文聚焦基于深度学习的轨道交通供电设备故障预测方法,首先概述轨道交通供电系统构成及牵引变压器、开关柜、接触网等核心设备的常见故障模式,随后介绍深度学习基本概念及适用于故障预测的LSTM、CNN、DBN等模型,进而阐述该方法的数据采集与预处理、模型构建与训练、评估与优化全流程,旨在通过深度学习技术提升轨道交通供电设备故障预测的准确性与效率,为保障供电系统稳定运行提供技术支持。

关键词: 基于深度学习;轨道交通;供电设备;故障预测;方法

引言:轨道交通作为城市公共交通的核心,其安全稳定运行高度依赖供电系统的可靠性。然而,供电设备长期处于复杂工况下,易因老化、负荷波动等因素发生故障,不仅影响行车安全,还可能造成巨大经济损失。传统故障预测方法多依赖人工经验或浅层机器学习,难以处理设备运行产生的海量非线性数据,预测精度有限。深度学习凭借强大的特征提取与非线性拟合能力,为解决这一问题提供了新途径。围绕基于深度学习的轨道交通供电设备故障预测方法展开研究,系统梳理相关技术与流程,以期为推动供电系统智能化运维、降低故障发生率提供理论与实践参考。

1 轨道交通供电设备概述

1.1 供电系统构成

轨道交通供电系统通常由外部电源引入部分、牵引供电系统和动力照明供电系统组成。外部电源通过城市电网变电站接入,经主变电所转换为适合轨道交通的电压等级;牵引供电系统包括牵引变电所、接触网(或接触轨)、馈线等,负责为列车提供牵引动力;动力照明系统则为车站、区间的通风、照明、通信等辅助设施供电。各子系统通过电缆、开关柜等设备连接,形成相互协同的闭环能源网络,其结构设计需满足列车启停频繁、负荷波动大的特殊用电需求。

1.2 常见供电设备类型及故障模式

1.2.1 牵引变压器

牵引变压器是将高压电网电压转换为列车适用电压的关键设备,其故障多与绝缘老化、过热及机械损伤相关。常见故障包括绕组绝缘击穿(因局部放电、油质劣化导致)、铁芯多点接地(引发涡流损耗过大、温度异常升高)、分接开关接触不良(造成电压波动或局部过

热)等。此类故障具有隐蔽性强、发展缓慢的特点,初期多表现为油中气体含量超标、局部温度异常,若未及时处理可能导致变压器停运,中断牵引供电。

1.2.2 开关柜

开关柜作为供电系统的控制与保护设备,负责电路的通断、过载及短路保护,其故障主要集中在电气连接与绝缘部件。常见故障有断路器拒动(因操动机构卡涩、线圈烧毁或控制回路故障)、绝缘闪络(受潮湿、灰尘影响,导致相间或对地放电)、触头过热(因接触电阻过大,长期发热引发烧损)等。开关柜故障可能导致供电回路误动或拒动,扩大故障影响范围,甚至引发区域性停电。

1.2.3 接触网(接触轨)

接触网(或接触轨)是列车获取电能的直接通道,暴露于户外或隧道环境中,易受机械磨损与自然环境影响。接触网常见故障包括导线磨损超标、零部件松动或断裂(如腕臂、定位器故障)、导高或拉出值偏差(导致受电弓离线);接触轨则易出现轨面磨损、绝缘支架损坏、接头接触不良等问题。此类故障直接影响列车取流稳定性,可能引发火花放电、列车骤停,甚至因受电弓与接触网摩擦加剧而造成设备损坏^[1]。

2 深度学习技术基础

2.1 深度学习基本概念

深度学习以多层神经网络为基础,其核心在于通过“深度”结构(通常包含输入层、多个隐藏层和输出层)实现特征的逐级转化。隐藏层通过非线性激活函数对输入数据进行加工,将低层特征(如设备运行的原始传感数据)逐步映射为高层特征(如故障模式的抽象表征)。关键概念包括神经元(网络的基本处理单元)、

权重（神经元间连接的强度参数）、反向传播（通过误差反馈优化权重的算法）等。深度学习的“端到端”学习能力，使其无需人工设计特征，直接从数据中学习预测规则。

2.2 适用于故障预测的深度学习模型

2.2.1 长短期记忆网络（LSTM）

LSTM是一种改进的循环神经网络（RNN），专为处理时序数据设计，能有效解决传统RNN的“梯度消失”或“梯度爆炸”问题。其核心在于通过输入门、遗忘门和输出门的门控机制，选择性保留或丢弃历史信息，例如在牵引变压器温度变化序列中，既能记住长期的温度趋势，又能捕捉短期的异常波动。这种特性使其适合预测设备性能随时间的退化过程，如基于历史电流、温度数据预测接触网的磨损趋势，在时序依赖强的故障预测场景中表现突出。

2.2.2 卷积神经网络（CNN）

CNN以卷积层为核心，通过局部感受野和权值共享机制，高效提取数据的局部特征和空间关联性。在供电设备故障预测中，可将多传感器采集的多维数据（如开关柜的电压、电流、温度信号）视为“类图像”数据，通过卷积操作捕捉不同信号间的耦合特征（如电压波动与触头过热的关联）。接触网的振动、位移信号中识别潜在的结构松动故障。

2.2.3 深度信念网络（DBN）

DBN由多个受限玻尔兹曼机（RBM）堆叠而成，是一种生成式深度学习模型，通过无监督预训练与有监督微调相结合的方式学习数据分布。预训练阶段，每层RBM从输入数据中逐层学习特征，如从变压器油中气体成分数据中提取故障相关的气体浓度模式；微调阶段则通过反向传播优化整体网络参数，提升预测精度。DBN对数据分布的适应性强，能处理非结构化或半结构化数据，尤其适用于供电设备故障样本不平衡场景，可通过生成虚拟样本增强模型的泛化能力^[2]。

3 基于深度学习的故障预测方法流程

3.1 数据采集与预处理

3.1.1 数据采集

数据采集需实现对供电设备全生命周期运行状态的覆盖，采集对象涵盖关键参数与环境信息。设备参数方面，包括牵引变压器的绝缘电阻、瓦斯继电器状态，开关柜的操作次数、绝缘介质损耗，接触网的磨损量、张力值等；环境信息则涉及温度、湿度、振动等外部影响因素。采集手段采用“分布式监测+集中式汇聚”架构：在设备关键部位部署智能传感器（如光纤光栅传感器、

红外测温传感器），实时采集高频动态数据；通过5G或工业以太网将数据传输至云端数据平台，同步整合设备台账、维修记录等静态数据。

3.1.2 数据预处理

预处理旨在将原始数据转化为模型可识别的结构化信息，主要包括四步操作。一是异常值处理，结合设备运行阈值（如变压器油温上限）与孤立森林算法，识别并修正传感器漂移导致的离群值；二是数据对齐，通过时间戳同步多源传感器数据，解决因传输延迟产生的时序错位问题；三是归一化处理，采用最大最小归一化将数据压缩至[0,1]区间，消除量纲差异对模型训练的干扰；四是特征筛选，利用皮尔逊相关系数剔除与故障无关的冗余特征（如环境温度与开关柜绝缘故障的弱关联特征），保留核心特征（如接触网磨损量与断裂故障的强关联特征）。处理后的数据需通过数据校验机制（如交叉验证）确保一致性，为模型训练提供可靠输入。

3.2 模型构建与训练

3.2.1 模型选择

模型选择需依据供电设备故障数据的类型与预测目标确定。对于牵引变压器油温、接触网电流等时序性强的数据，优先选择长短期记忆网络（LSTM），其门控机制可有效捕捉数据的时间依赖关系，适合预测设备性能随时间的退化趋势；针对开关柜多传感器采集的多维数据（如电压、电流、温度耦合信号），卷积神经网络（CNN）凭借局部特征提取能力，能更好挖掘不同参数间的关联故障模式；若面临故障样本稀缺或数据分布复杂的场景，深度信念网络（DBN）通过无监督预训练可提升模型对小样本数据的适应能力。实际应用中，也可采用混合模型（如LSTM-CNN），融合时序特征与空间特征，进一步提升复杂故障的预测精度。

3.2.2 模型参数设置

模型参数设置需结合设备数据规模与预测任务需求动态调整。以LSTM为例，关键参数包括隐藏层神经元数量（通常设为64-256，需根据输入特征维度调试）、时间步长（基于数据采集频率设定，如接触网数据取1小时内的60个时间步）、学习率（初始设为0.001，通过衰减策略避免过拟合）、迭代次数（一般为100-500轮，以验证集损失稳定为终止条件）。CNN需重点设置卷积核大小（如3×3或5×5，平衡特征提取粒度与计算效率）、池化窗口（常用2×2，降低数据维度）；DBN则需确定受限玻尔兹曼机层数（通常2-5层）与每层节点数，通过逐层预训练优化初始参数。

3.2.3 模型训练

模型训练采用“分阶段优化”策略，分为预训练与微调两个阶段。预训练阶段，利用预处理后的训练集数据对模型进行初步训练，如DBN通过无监督学习拟合数据分布，LSTM与CNN则采用随机梯度下降（SGD）或Adam优化器最小化预测误差（如均方误差损失函数）。训练过程中需引入早停机制，当验证集损失连续多轮（如10轮）上升时终止训练，避免过拟合。微调阶段，针对预训练模型在验证集上的表现，调整关键参数（如学习率衰减、增加正则化项），通过反向传播算法迭代优化网络权重。同时，采用批处理（BatchSize设为32-128）提升训练效率，结合GPU加速处理大规模供电设备数据，确保训练过程的稳定性与高效性。

3.2.4 提高模型的预测准确性

提升模型预测准确性需从数据、算法与训练策略多维度优化。数据层面，通过数据增强技术（如对时序数据进行时间轴拉伸、添加高斯噪声）扩充样本量，尤其针对故障样本稀缺问题，采用生成对抗网络（GAN）生成虚拟故障数据，平衡数据集分布。算法层面，引入注意力机制（如在LSTM中添加注意力层），使模型聚焦于与故障相关的关键特征（如变压器油中气体浓度突变时段）；融合多模型预测结果（如通过加权投票结合LSTM与CNN输出），降低单一模型的预测偏差。训练层面，采用交叉验证（如5折交叉验证）评估模型稳定性，通过网络搜索或贝叶斯优化自动调参，同时引入Dropout层（丢弃率设为0.2-0.5）抑制过拟合，最终通过测试集验证优化效果，确保模型在实际场景中的泛化能力。

3.3 模型评估与优化

3.3.1 评估指标选择

评估指标的选取需贴合供电设备故障预测的实际需求，兼顾不同预测目标的特性。对于故障与正常状态样本比例失衡的场景，需侧重能反映预测准确性与完整性的指标，例如通过精确率判断预测为故障的结果中真实故障的占比，通过召回率衡量实际发生的故障被成功识别的程度，两者的综合指标可平衡模型在减少误报与漏报之间的表现。针对设备状态随时间变化的趋势预测，需选用能体现预测值与实际状态偏差程度的指标，直观反映模型对状态演化规律的捕捉能力。

3.3.2 模型性能评估

模型性能评估需构建多维度验证体系，避免单一角度判断导致的偏差。首先需按照实际应用中的时间顺序划分验证数据，模拟模型在真实场景中的预测过程，确保评估结果的时效性。其次通过交叉验证方式检验模型在不同时段、不同设备运行状态下的稳定性，分析其是否受外部环境或设备工况波动的影响。针对不同类型的深度学习模型，需分别考察其对各类供电设备故障的预测表现，明确模型在处理特定故障模式时的优势与不足。

3.3.3 模型优化策略

模型优化需基于评估结果从多层面制定调整方案，实现性能的持续提升。在模型结构层面，若出现过拟合现象，可通过简化网络复杂度、增强正则化约束等方式提升泛化能力；若模型对核心特征捕捉不足，则需增加网络深度或拓宽特征处理维度。在数据应用层面，针对模型表现薄弱的故障类型，可通过主动采集该类故障相关信息扩充样本覆盖度，或借鉴相似场景的故障规律迁移学习经验。在实际部署中，需建立动态更新机制，定期结合新的设备运行状态数据调整模型参数，以适应设备老化、环境变化等因素带来的性能衰减，维持长期稳定的预测效果^[3]。

结束语

基于深度学习的轨道交通供电设备故障预测方法，通过整合多源运行数据与先进算法，为供电系统的智能化运维提供了全新路径。该方法突破传统预测技术的局限，借助LSTM、CNN等模型的特征学习能力，实现了对牵引变压器、开关柜等核心设备故障的精准预警，有效平衡了预测灵敏度与可靠性。未来，随着传感器技术与边缘计算的发展，需进一步优化模型轻量化部署方案，提升复杂环境下的实时预测能力。

参考文献

- [1]赵洪山,程亮亮.基于深度学习的电力设备故障诊断方法[J].电力系统自动化,2018,42(15):113-120.
- [2]尹相国,朱永利,俞乾.基于深度信念网络的电力设备故障诊断方法[J].电力系统保护与控制,2017,45(19):114-120.
- [3]李刚,于长海,刘云鹏,等.基于深度学习的电力变压器故障诊断模型及优化[J].高电压技术,2019,45(11):3522-3529.