

故障段漏缆后,监测系统显示该点位驻波比恢复至 1.05-1.08 的正常范围,告警彻底消除。

4.3 故障机理验证与根本原因分析

更换下的故障漏缆经实验室解剖分析,发现外导体存在明显变形褶皱(如图1所示),褶皱深度约 0.3mm,长度约 15mm,位于距起点 125.3 米处,与监测系统定位结果高度吻合。内导体和绝缘介质未见明显异常。



图1 故障漏缆外导体变形褶皱示意图

变形褶皱导致屏蔽层槽孔结构变形,改变了电磁波泄漏特性,引起阻抗不连续和信号反射,最终表现为驻波比异常。根本原因分析表明,该变形可能源于敷设过程中的机械应力集中,在温度变化引起的热胀冷缩作用下,缺陷逐渐扩大并显现。

这一案例证实了机械损伤与环境应力协同作用导致的隐性故障机理,也凸显了传统外观检查的局限性,以及智能监测在发现内部缺陷方面的优势。

5 LCC 故障智能防控体系构建

5.1 多源融合的在线监测平台架构

基于 0558-RU 案例的经验,构建了集感知层、传输层、平台层和应用层于一体的 LCC 智能监测平台。

感知层部署多类型传感器,包括:分布式光纤传感器(DTS/DAS)用于温度和振动监测;射频传感器用于驻波比和回波损耗测量;电流电压传感器用于电气参数采集;环境传感器用于温湿度、盐度等环境参数监测。传感器布设密度根据故障概率分布优化设计,重点区域监测点间距不超过 50 米。

传输层采用工业以太网和无线通信混合组网,确保数据实时可靠传输。在铁路环境中,特别考虑了电磁兼容性和防雷保护要求。

平台层基于云计算和大数据技术,构建数据存储、处理和分析能力。平台日均处理数据量超过 10TB,采用时序数据库和分布式存储架构,支持毫秒级数据查询和分析。

应用层提供故障预警、健康评估、决策支持等功能。基于机器学习算法开发的故障预测模型,可实现提前 7—30 天的故障预警,准确率达 85% 以上。

5.2 智能诊断与预测性维护技术

智能诊断系统融合多源监测数据,采用层次化诊断策略:第一层基于规则引擎实现实时异常检测;第二层采用信号处理技术(如小波分析、频谱分析)进行故障特征提取;第三层应用深度学习模型(如 CNN、LSTM)实现故障分类和严重程度评估。

5.3 全寿命周期防控措施与标准化流程

LCC 全寿命周期管理涵盖设计、施工、运维和报废四个阶段,各阶段关键控制点如下:

设计阶段:开展环境适应性设计,选用耐腐蚀、抗疲劳材料;进行可靠性预计和故障模式影响分析(FMEA);优化槽孔结构设计,减少阻抗波动。

施工阶段:严格控制敷设张力和弯曲半径(通常不小于电缆外径的 15 倍);规范接头处理工艺,确保防水密封性能;实施施工质量全过程监控。

运维阶段:建立"日常巡检+定期检测+专项评估"的多级运维体系;基于监测数据动态调整巡检周期和内容;推广模块化更换和快速修复技术。

报废阶段:制定科学的退役评估标准;规范废旧电缆回收处理流程,提高资源再利用率。

6 结语

本文通过理论分析与案例实证相结合的方法,系统研究了铁路漏泄同轴电缆的故障机理与智能防控策略:

第一,LCC 故障主要源于环境腐蚀、机械损伤和电气击穿三大机理,且多为多因素耦合作用的渐进性过程。0558-RU 基站案例表明,外导体变形等隐性故障难以通过传统手段及时发现,智能监测系统在此类故障的早期预警中发挥关键作用。第二,基于多源信息融合的智能监测平台可实现 LCC 运行状态的实时感知和精准评估。监测数据表明,该系统可将故障定位精度控制在 ± 5 米以内,预警准确率超过 85%,显著提升运维效率。第三,预测性维护策略可有效降低 LCC 全寿命周期成本。实证分析显示,智能运维体系可将 MTTR 缩短 75% 以上,运维成本降低 20%-30%,设备使用寿命延长 2-3 年。

随着 5G-R、北斗导航等新技术在铁路领域的推广应用,LCC 将面临更高频段、更高速率的传输需求。未来研究应重点关注以下方向:一是开发基于光子晶体和超材料的新一代 LCC,提升高频传输性能;二是探索数字孪生技术在 LCC 运维中的应用,实现物理实体与虚拟模型的深度融合;三是研究基于区块链技术的 LCC 全寿命周期数据管理,提高数据可信度和追溯性。

只有持续推动技术创新与运维模式变革,才能构建更加安全、高效、智能的铁路通信系统,为交通强国建设提供坚实基础保障。

参考文献

- [1] 陈小平. 高速铁路漏泄同轴电缆智能检测系统[J]. 铁道通信信号, 2021,57(12):48-52.
- [2] 张国光. 铁路无线列车调度用漏泄同轴电缆的配置及接续技术[J]. 有线电视技术, 2008,(02):115-117.
- [3] 王震, 江兰, 章明明, 等. 铁路无线通信用漏泄同轴电缆设计[J]. 电子科技, 2012,25(05):30-33.
- [4] 刘爽. 漏泄同轴电缆间耦合分析及隔离度提升研究[D]. 华中科技大学, 2022.

AI phase recognition improves load management efficiency

Qian Han

State Grid Xiaogan Power Supply Company, Xiaogan, Hubei, 432000, China

Abstract

To address challenges in distribution network management such as low-efficiency phase identification for low-voltage users and power supply reliability issues caused by three-phase imbalance leading to increased line losses, this paper proposes an AI-based phase recognition solution for low-voltage users based on the practical experience of Xiaogan Power Supply Company. The solution utilizes a data platform and measurement center to collect current, voltage, and power data from distribution transformers and low-voltage users at 15-minute intervals. A convolutional neural network (CNN) model with input layers, convolutional layers, pooling layers, fully connected layers, and output layers is constructed. Through cross-entropy loss function training (with 84 transformer districts and 504 samples achieving 100% accuracy after training), combined with power data-assisted verification (error $\leq 2\%$ indicates correct judgment), precise phase recognition is achieved.

Keywords

AI phase recognition; Convolutional neural network; Low-voltage users; Three-phase imbalance; Load management; Distribution network management

AI 相位识别提升负荷管理效能

韩骞

国网孝感供电公司, 中国 · 湖北 孝感 432000

摘 要

针对配网管理中低压用户相位识别依赖人工、效率低下, 以及三相不平衡引发的供电可靠性下降、线损上升等问题, 本文以孝感供电公司实践为基础, 提出基于人工智能的低压用户相位识别方案。该方案依托数据中台与量测中心, 以15分钟为间隔采集配变及低压用户的电流、电压、功率数据, 构建包含输入层、卷积层、池化层、全连接层及输出层的卷积神经网络 (CNN) 模型, 通过交叉熵损失函数训练 (84个台区504条样本训练后正确率达 100%), 结合功率数据辅助验证 (误差 $\leq 2\%$ 判定正确) 实现相位精准识别。

关键词

AI相位识别; 卷积神经网络; 低压用户; 三相不平衡; 负荷管理; 配网管理

1 引言

随着配网管理要求的日益提高, 配变三相不平衡所带来的供电可靠性下降、电能质量不达标、线路损耗上升等问题日益突出, 而配网设备点多面广, 传统手段不能有效覆盖, 急需数字化手段提升配网管理水平。目前供电公司对于低压用户挂接相位无法清晰感知, 低压用户相位的识别一直依靠人工现场检查、现场测量获取相关信息, 工作任务不仅繁重且效率低下, 各种专业管理系统也缺乏对低压用户挂接相位准确记录。随着全社会对于电压质量和优质服务的要求进一步的提高, 利用人工智能及算法对低压用户开展相位的识别能够精确指导基层站所开展低压用户调相工作, 从而有效的杜绝因低压用户三相挂接不均衡引起的重过载、低电压等问


题, 提升供电可靠性, 提升优质服务水平。孝感供电公司通过积极探索利用配变、低压用户的电流、电压、功率等大数据基于一定的算法, 通过人工智能不断修正和判别, 开发了基于低压用户的 AI 相位识别应用, 为精确支撑低电压用户调节提供数据支撑, 进一步提升供电电压质量。

2 做法

配网低压用户相位识别测算方法如下: 一是大数据获取。依托公司数据中台、量测中心, 以 15 分钟为一个数据采集间隔。全量获取公司配变、低压用户的电流、电压、功率等数据。

二是搭建卷积神经网络的深度学习进行相位识别。卷积神经网络 (Convolutional Neural Network, CNN) 对用户电压数据进行相位识别评估。网络结构如下图:

【作者简介】韩骞 (1983-), 男, 中国湖北孝感人, 本科, 工程师, 从事工程技术专业研究。



神经网络包含输入层，三个卷积层（在上图中卷积层涵盖卷积部分和池化部分），全连接层以及输出层。下面分别对每一层的作用进行介绍：

输入层 (Input Layer): 输入层接收用户的电压数据，且将其转换为 30×96 的矩阵数据并予以归一化处理，接着将所得结果传递给下一层的神经元。训练前，为避免各个输入变量的数量级差异过大，影响求解算法的效果，一般会先将数据归一化到 $[-1, 1]$ 的区间。公式如下：

$$x = 2 * \frac{x_0 - x_{min}}{x_{max} - x_{min}} - 1$$

式中 x 为归一化后的数据； x_0 为原始数据； x_{max} 为原始数据最大值； x_{min} 为原始数据最小值。

卷积层 (Convolutional Layer): 卷积层通过应用卷积核来提取输入数据的局部特征，采用参数共享的方式，减少了需要训练的参数数量，从而减少了过拟合的风险。第一个卷积层通常包含若干个卷积核，用于提取输入数据的特征。二维卷积计算公式如下：


$$s(i, j) = (X * W)(i, j) = \sum_m \sum_n x(i + m, j + n) w(m, n)$$

X 为输入矩阵， W 为 $m \times n$ 的卷积核矩阵。

卷积层的输出采用 ReLU 激活函数，ReLU 激活函数是分段线性函数，且每段的导数都能简单，导数要么为 0，要么为 1。计算简单，使用梯度下降法时收敛的更快。因此，在训练过程中能够大幅加快训练速度。数学表达式如下：


$$f(x) = \max(0, x)$$

其对应的函数图像如下所示：




池化层 (Pooling Layer): 池化层用于对卷积层的输出进行降维，实现下采样，减少参数数量，同时保留重要的特征。本研究采用平均池化，窗口大小为 2×2 。计算区域子块所包含

所有像素点的均值，将均值作为平均池化结果。计算过程如下图所示：



全连接层 (Fully Connected Layer): 全连接层由 1080 个感知器神经元组成，感知器是模拟生物神经元行为的机器，有与生物神经元相对应的部件，如权重（突触）、偏置（阈值）及激活函数（细胞体），输出为 0 或 1。单个感知器神经元的结构如下：



数学公式：

$$y = \text{sigmoid}(\sum_{j=1}^m w_j x_j + b)$$

sigmoid 激活函数：

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

输出层 (Output Layer): 输出层使用 Softmax 激活函数，用于输出 3 个数字类别，分别代用户电压属于 ABC 三相的概率分布。

Softmax 回归函数能够将输出转化为多个类别的概率分布，使得模型输出的结果更加直观和易于解释。此回归函数适用于多分类问题，能够处理多个类别的分类任务。并且在梯度下降等优化算法具有良好的凸性质，有利于模型参数的优化和收敛。

计算公式如下：

$$Y(x_i) = \text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=0}^2 e^{x_j}}$$

得到输出向量 $Y=[y_0, y_1, y_2]$, y_0 表示电压数据属于 A 相的概率值, y_1 表示电压数据属于 B 相的概率值, y_2 表示电压数据属于 C 相的概率值。

三是模型训练。采用交叉熵损失函数，交叉熵损失衡