

Application of Deep Learning Algorithms in Fault Detection of Power Metering Devices by

Zhenya Wu

State Grid Shandong Electric Power Company, Heze City Dingtao District Power Supply Company, Heze, Shandong, 274100, China

Abstract

With the continuous upgrades of China's smart electricity meters, collection terminals, and metering master stations, fault detection for power metering devices has evolved from on-site manual inspections and rule-based comparisons to online diagnosis driven by multi-source data. The emphasis on deep learning algorithms in this context stems not from their novelty, but from the fact that metering faults often manifest as a combination of signals—including sudden load curve changes, consecutive event triggers, degraded communication quality, abnormal infrared temperature rises, and display component defects—making a single threshold insufficient for comprehensive coverage. Current metering standards, communication protocols, metering systems, and field inspection procedures provide a relatively complete data foundation; the critical task now lies in organizing load, voltage, current, event data, and images into diagnostic models that are trainable, verifiable, and implementable.

Keywords

power system; deep learning algorithm; power metering device; fault detection; application

深度学习算法在电力计量装置故障检测中的应用

吴振亚

国网山东省电力公司菏泽市定陶区供电公司, 中国·山东 菏泽 274100

摘要

随着中国智能电能表、采集终端和计量主站持续升级, 电力计量装置故障检测已经从现场人工巡检和规则比对, 逐步转向多源数据驱动的在线诊断。深度学习算法之所以在这一场景中受到重视, 不是因为概念新, 而是因为计量故障往往会同时表现为负荷曲线突变、事件记录连续触发、通信质量下降、红外温升异常和显示部件缺陷等多类信号, 单一阈值难以稳定覆盖。当前计量标准、通信协议、用采系统和现场检验规程已经提供了较完整的数据基础, 关键工作转向怎样把负荷、电压、电流、事件和图像组织成可训练、可复核、可落地的诊断模型。

关键词

电力系统; 深度学习算法; 电力计量装置; 故障检测; 应用

1 引言

电力计量装置的准确运行能够有效提高电力系统供电的可靠性。但是, 目前受各种因素的影响, 电力计量装置可能会出现故障, 进而对电力计量的准确性产生影响。电力计量装置直接关系电量结算、公平交易和线损治理。当前计量现场已形成“智能电能表、采集终端、主站系统、现场检验”相衔接的运行体系, 但失压、失流、接线异常、时钟漂移、显示缺陷和局部过热等问题仍具有隐蔽性和连续性^[1]。把深度学习算法引入故障检测, 不在于替代规程, 而在于用算法提高异常发现速度, 缩小人工复核范围, 并把分散的计量数据转化为可执行的检修线索。

【作者简介】吴振亚(1999-), 男, 中国山东菏泽人, 本科, 助理工程师, 从事输配电及用电工程电能计量方向研究。

2 深度学习算法概述

深度学习算法在电力计量装置故障检测中的含义, 不能只理解成用神经网络替代人工判断, 更准确的表述应是: 依托智能电能表、采集终端、负荷曲线、事件记录、红外图像和现场检验结果等多源数据, 让模型自动提取与故障状态有关的时序特征、空间特征和关联特征, 再完成异常识别、故障分型和风险排序。中国现行计量通信和管理体系已经为这一过程提供了基础条件, 例如 DL/T 645-2007 完善了事件记录、冻结量和负荷记录的抄读规则, 电能表相关国家标准修订说明又把准确度等级、高次谐波、不平衡负载和软件保护纳入重点要求, 这说明计量故障并非只看单点误差, 而要结合运行过程综合判断。对计量专业来说, 深度学习真正有用之处, 在于它能够处理数据标识不全、故障边界不固定、人工特征难统一的现场问题, 并把原本依靠经验串联的判别

过程转化为可重复执行的模型流程。

3 深度学习算法在电力计量装置故障检测中的应用要点

3.1 负荷曲线时序建模

把深度学习真正用于计量装置故障检测，首先要抓住负荷曲线这一类连续时序数据，而不是只盯住单次告警。计量专业在建模时应优先选取 15 min 负荷曲线、日电量、瞬时电压、电流、功率因数和日冻结数据构成滑动时间窗，因为中国用采场景已经稳定具备 15 min 曲线采集条件，按日组织后天然形成 96 个时刻点，既便于 LSTM 学习上下文，也便于现场人员按日校核。对专变和关口计量点，还应把需量、反向有功和三相不平衡特征一并纳入，以避免模型只学到居民表的单一模式。其次，样本标签不能简单写成“异常”二字，而应拆成失压倾向、失流倾向、时钟漂移倾向、采集失真倾向和疑似计量偏差等可复核类别，使模型输出能够直接进入工单分派。标签来源宜以现场检验、轮换拆回检测和历史缺陷闭环结果为准，不能只用营销稽查结果替代，否则容易把窃电、停电和设备故障混在一起。再次，在训练前必须先做缺失补齐、节假日分层和季节归一，否则居民、工商业和专变用户的负荷形态差异会把模型带偏；对突增突降点还要结合台区相邻表计和天气信息二次甄别，避免把大面积停电、负荷转移或高温天气导致的集体波动误当单表故障^[2]。最后，模型评估不能只看准确率，还要同时看召回率、误报量和人工复核压降比例，因为计量场景最怕把正常表判成故障表，增加无效复检。有关研究表明，面向用户电量异常检测的混合 CNN-LSTM 模型准确率达到 89.3%、召回率达到 69%，而智能电表数据异常检测研究又普遍采用 LSTM、自编码器网络联合建模，这类结果说明时序模型适合作为前置筛查器，而不宜直接替代最终计量判定。

3.2 事件记录序列识别

计量装置故障在现场并不总是先表现为电量异常，更多时候先表现为事件链条紊乱，因此第二个要点是把事件记录按发生顺序交给模型识别。做法上应把失压、失流、断相、开盖、掉电上电、参数改写、通信中断等事件按时间戳重新编码，形成事件序列输入，而不是只统计某类事件出现了多少次。这样处理的原因在于，同样是三次失压，若它们集中出现在大负荷时段，更可能指向二次回路接触不良；若它们伴随通信失败和时钟跳变，则更可能指向终端供电或表内模块异常；若它们总在人工操作窗口出现，则通常属于运维动作而非故障。其次，训练集要保留“正常扰动样本”，例如检修停电、计划换表、远程参数下发、停复电试验和费控拉合闸等业务动作，否则模型会把正常运维当作故障，后期误报会非常集中。对关口表和高压用户，还应把互感器检修、二次回路切换、保护试验等特殊工况单列样本。再次，序列识别结果要与主站规则并行输出，规则负责硬约束，深度学

习负责识别复杂先后关系，两者不宜互相替代；规则先筛掉无效事件后再送入模型，能够明显降低噪声。最后，现场复核时应回看事件前后至少 1 个负荷周期和同台区邻近表计状态，以避免只凭单表事件做判断，并要同步核对该表最近一次现场检验结论。在模型结构上，可采用嵌入层加双向时序网络或事件卷积结构，把事件间隔时间、事件类型和持续时长同时编码，避免只学到事件名称而忽略事件间距^[3]。对连续同类事件还应做压缩和分段处理，防止长序列把少量关键事件淹没。多功能电能表通信规约已经完善事件记录、冻结量和负荷记录的抄读规则，计量在线监测异常本身也可由主站判别和终端上报两条路径形成，常见三相智能表还普遍具备失压、失流、断相事件记录与报警输出能力，这为事件序列建模提供了直接的数据入口。

3.3 运行状态多特征分类

除了做时间序列预测，计量专业还应把现场检验参数组织成适合卷积网络识别的状态矩阵，用于故障分型而不是简单预警。具体做法是把电压、电流、相角、功率因数、表计误差、三相不平衡度、通信成功率、日冻结完整率以及互感器二次负荷等指标按统一顺序排布，构造成固定尺寸的二维特征面，使卷积核去捕捉参数之间的组合关系。这样处理的优点在于，很多计量故障并不是某一项指标超限，而是几项指标同时轻度偏离，例如电流波动不大但相角异常、误差偏大且二次负荷偏离正常区间，或者冻结完整率下降同时伴随功率因数突变，这类组合关系靠人工规则往往很难一次写全。其次，输入特征必须先经过物理约束清洗，例如计量系统设计规程提出互感器二次回路实际负荷宜处于额定二次负荷的 25% 至 100% 范围，明显脱离该范围的数据应先作为配置或接线异常候选处理，而不应直接拿去训练；对不满足基本电气逻辑的数据，还要先做剔除和标记。再次，模型训练要按表计类型、接入方式和用户类别分层，避免把居民单相表和高压关口表混训，也不要直接把接入表和经互感器接入表放在同一标签体系中，否则模型表面精度会提高，现场可用性却会下降。最后，模型输出应落到“疑似 CT 异常”“疑似 PT 异常”“疑似二次回路异常”“疑似表计本体异常”等可执行类别，并附上触发该类别的关键特征，以便专业人员快速复核。对于故障样本稀缺的关口计量点，可先用正常样本建立健康基线，再做小样本增量学习，以减少高压计量装置故障样本少带来的训练偏差；但增量模型上线前仍应经过现场抽检复核。已有公开论文提出基于卷积神经网络的计量装置运行状态异常诊断方法，并指出其分类效果优于传统神经网络，这一路径更贴合计量运维的故障分型需求。

3.4 红外热缺陷目标检测

对电能表本体、接线盒和辅助模块开展红外图像检测，是近两年计量故障前移发现最实用的方向之一。第一，模型对象不能泛化成“整块表箱”，而应细化到接线盒、电池模

块、显示屏等高发部位,因为热缺陷多数先出现在局部连接点或供电单元,框得太大反而会稀释特征;对关口柜和计量屏则应进一步拆到端子、压接点和模块电源层级。第二,训练样本必须覆盖晴天反光、箱体污渍、夜间巡检、遮挡和小目标场景,尤其是接线盒热斑面积往往小、背景金属边缘多,若数据集过于整洁,现场一上线就会漏检;对不同厂家表型和不同安装高度也要做均衡采样。第三,红外模型输出不能只给是否异常,还要同步输出位置框、置信度和部件类别,让复核人员知道应先开箱看哪里,并可与历史同位置热像做升温趋势比对。第四,热缺陷识别结果必须和计量电气量同步交叉验证,例如升温异常但负荷长期平稳,可优先怀疑接点老化;若升温与负荷波动同时异常,再考虑接线松动或内部元件退化;若升温异常仅在高日照时出现,则要防止把环境反射误认为缺陷。在部署方式上,红外模型宜与可见光台账绑定,同一设备编号下同时保存热像、可见光图和本次负荷值,避免模型虽能框出热斑,却无法对应到具体资产和历史缺陷记录,影响后续处理效率。比如陈方彬等人研究成果表明,面向智能电能表热缺陷的YOLO-MCSL模型对接线盒、电池模块和显示屏三类关键部件的检测精度分别达到91.6%、99.2%和99.5%,整体mAP@0.5达到97.9%,参数量仅1.749 M,较YOLOv8s减少84.3%,这说明热缺陷模型已经具备较强的现场部署条件^[4]。

3.5 轻量化边云协同部署

深度学习算法能否在计量故障检测中真正落地,关键不在模型名字,而在部署链条是否适配现有计量系统。首先,边端模型负责快筛,主站模型负责复判。中国新一代用电信息采集系统已经把负荷数据采集周期由1 h压缩到15 min,首轮电量数据入库时长由30 min缩短到5 min,江苏试点分钟级用电示数采集成功率达到99.7%,这意味着主站完全可以承担更复杂的复判模型;对核心保电客户,15 min负荷曲线采集成功率已达到99.97%,进一步说明高质量样本可稳定获得。其次,现场表计和终端侧仍要考虑通信资源约束,现网电能表常见远红外默认速率为1200 bps、RS485默认速率为2400 bps,需量周期信号脉冲为80 ms ± 20 ms,因此边

侧算法更适合部署轻量网络或只下发候选样本,而不宜要求表端直接完成大模型推理。再次,模型上线后不能长期固定,应按月回灌现场复检结果,持续修正阈值和类别边界,尤其要把误报工单重新标注为“正常波动”或“计划检修”,把漏报样本单独纳入下一轮训练;对新表型和新固件版本还要单独做小批量复训。此外,边云协同的样本回传应与表计资产台账、现场检验报告和换表记录打通,保证每一次模型命中都能追溯到具体设备、具体工单和具体处理结果,避免形成只报警不闭环的孤立系统^[5]。最后,边云协同必须保留人工兜底,深度学习输出应先进入计量在线监测清单,再由专业人员结合现场检验规程确认,不能直接触发计费追补、责任认定或资产报废。边端负责缩小排查范围,主站负责综合判断,人工负责最终确认,这样的闭环才符合当前中国计量管理实际。

4 结语

综上所述,深度学习算法进入电力计量装置故障检测后,真正改变的不是规程本身,而是异常发现顺序、复核范围和运维组织方式。对当前中国场景而言,可落地的路径不是盲目追求更大的模型,而是围绕负荷曲线、事件序列、状态矩阵、红外图像和现场闭环数据分别建立适配的诊断单元,再通过边云协同把模型结果纳入计量在线监测和现场检验流程。只有把算法判断、物理约束和人工复核同时保留下来,深度学习才能在公平计量和设备运维中发挥稳定作用。

参考文献

- [1] 谢文斌,刘玲.深度学习算法在电力计量装置故障检测中的应用[J]. 2025(7):47-49.
- [2] 韩玉环,秦志沁,张毅,等.基于深度学习的电能计量装置运行状态评估模型研究[J].太原理工大学学报, 2024, 55(1):111-119.
- [3] 张笑逆.电力计量装置故障智能化检测技术研究[J]. 2026(1):128-130.
- [4] 陈方彬,陈祖财.一种基于改进YOLOv8s的轻量化关口电能表热缺陷目标检测方法:CN202510132528.2[P].CN120032112A.
- [5] 王翰林,洪诚程,唐修明.智能控制技术在电力计量装置故障诊断和维护中的应用[J]. 2025(9):340-341.