

# 基于边缘计算的智能电表实时用电行为分析

程凌法

杭州炬华科技股份有限公司 浙江 杭州 311121

**摘要:** 随着新型电力系统和能源互联网的快速发展,海量智能电表产生的高维、高频用电数据为精细化用电管理与服务提供了前所未有的机遇。然而,传统的“端-云”集中式数据处理架构在面对大规模、低时延、高带宽的实时用电行为分析需求时,暴露出网络拥塞、响应延迟、隐私泄露及云端计算资源瓶颈等诸多挑战。为应对上述问题,本文提出一种基于边缘计算的智能电表实时用电行为分析框架。该框架将计算、存储与智能分析能力下沉至靠近数据源的网络边缘(如配变台区或社区网关),通过在边缘侧部署轻量级深度学习模型,实现对用户用电负荷的本地化实时分解、异常检测与模式识别。本文详细阐述了该框架的系统架构、核心算法设计、隐私保护机制及典型应用场景。所提方法能够有效支撑电网侧的精准需求响应、故障预警与反窃电稽查,以及用户侧的个性化能效管理服务,为构建安全、高效、绿色的未来智能用电生态提供了关键技术路径。

**关键词:** 边缘计算;智能电表;用电行为分析;非侵入式负荷监测;实时异常检测

## 引言

在全球能源结构转型与“双碳”目标推动下,以新能源为主体的新型电力系统加速构建,智能电表成为连接电网与用户“最后一公里”的关键节点,已演变为集数据采集等功能于一体的智能终端。截至2025年底,我国智能电表覆盖率近100%,形成庞大感知网络,持续产生海量用电负荷数据,蕴含丰富用户用电行为特征,是电网精细化运营等核心资产,对用电行为深入分析在电网和用户侧应用价值广泛。但传统“端-云”架构的用电行为分析范式面临网络带宽压力大、实时性难保障、云端计算成本高、用户隐私风险突出等挑战。边缘计算作为新兴分布式计算范式,将服务下沉到网络边缘,能有效破解困局。本文旨在探索边缘计算与智能电表深度融合技术路径,构建面向实时用电行为分析的边缘智能框架。

## 1 相关工作

### 1.1 用电行为分析技术

用电行为分析的核心任务之一是非侵入式负荷监测(NILM)。Hart在其开创性工作中首次提出NILM概念,旨在仅通过总入口处的聚合功率信号,分解出内部各个电器的运行状态与能耗。早期方法主要基于事件检测(Event-based)和启发式规则(如Viterbi解码),但对噪声敏感且泛化能力差<sup>[1]</sup>。近年来,深度学习技术,特别是循环神经网络(RNN)、长短期记忆网络(LSTM)和卷积神经网络(CNN),因其强大的序列建模和特征提取能力,在NILM领域取得了显著突破。然而,这些模型通常计算复杂度高、参数量大,难以直接部署在资源受限

的边缘设备上。

### 1.2 边缘计算在电力物联网中的应用

边缘计算在电力系统中的应用研究方兴未艾。现有工作多聚焦于配电网的故障定位、状态估计和分布式能源协调控制。在用电信息采集领域,部分研究开始探索边缘计算用于数据压缩、协议转换和简单的阈值告警。然而,针对用电行为这一更深层次、更复杂的分析任务,如何在边缘侧高效、准确地执行,尤其是在模型轻量化、资源调度和隐私保护等方面,仍缺乏系统性的研究与实践。

### 1.3 轻量化模型与隐私保护

为适应边缘计算环境,模型压缩技术(如剪枝、量化、知识蒸馏)被广泛用于降低深度学习模型的复杂度。MobileNet、SqueezeNet等轻量级网络架构为此提供了重要参考。在隐私保护方面,联邦学习(Federated Learning)允许在不共享原始数据的情况下协同训练模型,但其通信开销大,对异步性和数据非独立同分布(Non-IID)敏感。相比之下,差分隐私通过向查询结果或模型参数中注入可控的噪声,提供可证明的隐私保障,更适合于单个边缘节点的本地化分析场景。

综上所述,现有研究尚未充分解决在边缘侧进行实时、高效、隐私安全的用电行为深度分析这一综合性问题。本文的工作正是在此背景下展开。

## 2 系统架构设计

本文提出的“基于边缘计算的智能电表实时用电行为分析”系统采用三层协同架构:

### 2.1 感知层(端)

感知层由部署在用户侧的智能电表组成。它们负责

以高频率（例如每15秒或1分钟）采集用户的电压、电流、有功/无功功率、谐波等多维度电气量数据，并通过本地通信网络（如HPLC、LoRa、NB-IoT）将原始数据流发送至边缘层。智能电表本身计算能力有限，主要承担数据采集与传输功能。

## 2.2 边缘层（边）

边缘层是本系统的核心，通常部署在配变台区的智能融合终端或社区/楼宇的数据网关上。它具备较强的本地计算、存储和网络能力。边缘节点的主要职责包括：（1）数据接入与预处理：接收来自辖区内所有智能电表的原始数据流，进行时间戳对齐、缺失值填充、噪声滤波等预处理操作。（2）本地智能分析：部署并运行轻量化的用电行为分析模型，执行实时的负荷分解（NILM）、异常用电检测、基础用电模式聚类等任务<sup>[2]</sup>。（3）隐私保护处理：在数据离开边缘节点之前，应用差分隐私等技术对分析结果进行扰动，确保上传数据的隐私性。（4）协同与上报：根据预设策略或云端指令，将经过处理的、有价值的元数据（如分解后的各电器能耗、异常事件告警、聚合统计特征）周期性或事件触发式地上报给云端。同时，边缘节点之间也可进行横向协同，共享模型更新或全局知识。

## 2.3 云平台层（云）

云平台层作为系统的顶层，拥有近乎无限的计算与存储资源。其主要功能包括：（1）全局数据汇聚与存储：接收并存储来自所有边缘节点上报的元数据，构建全局的用电行为知识库。（2）高级分析与决策：执行更为复杂的、非实时的全局性分析任务，如跨区域用电模式挖掘、长期负荷预测、大规模需求响应策略制定、窃电嫌疑用户画像等。（3）模型训练与下发：利用汇聚的全局数据，在云端训练高精度的基准模型。然后，通过模型压缩和知识蒸馏等技术，生成适用于边缘部署的轻量化模型，并将其安全地下发至各边缘节点，实现模型的持续迭代与优化。（4）可视化与服务接口：为电网运营人员和终端用户提供Web或移动应用界面，展示分析结果，并提供API供第三方应用调用。

该“端-边-云”架构通过任务卸载与分层处理，有效平衡了实时性、计算负载与数据隐私之间的矛盾。

## 3 核心算法设计与优化

为在资源受限的边缘设备上高效执行用电行为分析，我们重点设计了两个核心算法：轻量化NILM模型和实时异常检测模型。

### 3.1 基于轻量化CNN的非侵入式负荷监测（NILM）

传统的深度NILM模型（如Seq2Point）虽然精度高，

但其庞大的参数量和计算量使其无法在边缘设备上实时运行。为此，我们设计了一个基于一维深度可分离卷积（Depthwise Separable Convolution）的轻量化CNN模型。

#### 3.1.1 模型结构

输入为一段窗口长度为W的总有功功率序列。首先通过若干层深度可分离卷积块进行特征提取。深度可分离卷积将标准卷积分解为逐通道卷积（Depthwise Conv）和逐点卷积（Pointwise Conv），能大幅减少参数量和计算量（理论计算量可降至标准卷积的 $1/N + 1/D^2$ ，其中N为输入通道数，D为卷积核尺寸）<sup>[3]</sup>。每个卷积块后接批归一化（Batch Normalization）和ReLU激活函数。最后，通过全局平均池化（Global Average Pooling）和全连接层输出目标电器（如空调、冰箱）在该时间窗口内的平均功率估计值。

#### 3.1.2 模型压缩

在云端训练好高精度的教师模型（Teacher Model）后，我们采用知识蒸馏（Knowledge Distillation）技术来训练上述轻量级学生模型（Student Model）。学生模型不仅学习真实标签，还学习模仿教师模型的软概率输出（Soft Targets），从而在保持较小规模的同时，继承教师模型的大部分判别能力。

#### 3.1.3 边缘部署

训练好的学生模型经过量化（Quantization）处理（如从FP32转为INT8），进一步减小模型体积并加速推理。最终，该轻量化模型被部署在边缘节点上，对本地智能电表数据进行实时负荷分解。

### 3.2 基于自编码器的实时异常用电检测

异常用电行为（如窃电、设备故障）通常表现为用电模式与正常历史模式的显著偏离。我们采用自编码器（Autoencoder）来学习用户的正常用电模式。

#### 3.2.1 模型原理

自编码器是一种无监督神经网络，由编码器（Encoder）和解码器（Decoder）组成。编码器将输入数据压缩到一个低维的潜在表示（Latent Representation），解码器则尝试从该潜在表示重构出原始输入。当模型在正常数据上训练完成后，它对正常样本的重构误差（Reconstruction Error）会很小，而对异常样本的重构误差则会很大。

#### 3.2.2 轻量化设计

构建一个浅层的、全连接的自编码器。输入为经过标准化处理的日负荷曲线（96点/15分钟）。编码器和解码器各包含1-2个隐藏层，使用ReLU激活。为了适应边缘环境，我们严格限制了隐藏层的神经元数量。

#### 3.2.3 在线检测流程

边缘节点为每个用户维护一个个性化的自编码器模型(可在云端初始化后下发)。当新的日负荷数据到达时,模型对其进行重构,并计算均方误差(MSE)作为异常分数。若该分数超过预设的动态阈值(可根据历史误差分布自适应调整),则立即触发异常告警,并将告警信息(而非原始数据)上报云端进行进一步核查。

#### 4 隐私保护机制

在边缘侧进行本地化分析本身就减少了原始敏感数据的外传,构成了第一道隐私防线。为进一步增强隐私保障,我们在边缘节点的数据上报环节引入了差分隐私(DP)技术。具体而言,对于需要上报的聚合统计量(例如,某社区内开启空调的用户比例),采用拉普拉斯机制(Laplace Mechanism)。假设查询函数 $f$ 的全局敏感度(Global Sensitivity)为 $\Delta f$ ,为了满足 $\epsilon$ -差分隐私,我们向查询结果 $f(D)$ 中添加从拉普拉斯分布 $Lap(\Delta f/\epsilon)$ 中抽取的噪声 $\eta$ 。

$$M(D) = f(D) + \eta, \text{ where } \eta \sim Lap(\Delta f/\epsilon)$$

其中,隐私预算 $\epsilon$ 是一个正实数,用于量化隐私保护的强度。 $\epsilon$ 越小,添加的噪声越大,隐私保护越强,但数据可用性(精度)越低;反之亦然。边缘节点可以根据上报数据的敏感程度和业务需求,动态调整 $\epsilon$ 值,在隐私与效用之间取得平衡。通过这种方式,即使攻击者截获了上报的数据,也无法以高置信度推断出任何一个特定用户的用电情况,从而实现了可证明的隐私保护。

#### 5 典型应用场景

所提出的边缘智能分析框架在电网运营与用户服务中具有广泛的应用前景。在电网侧,边缘节点可实时识别异常用电模式(如电量突降、波形畸变),实现分钟级窃电告警,大幅提升稽查效率;同时,通过本地负荷分解获取的空调、电动汽车等可调节资源信息,可支撑台区级精准需求响应,有效缓解局部过载<sup>[4]</sup>。在用户侧,系统能为用户提供细粒度的电器能耗可视化与能效诊断,并基

于其用电习惯推送个性化节能建议。此外,该框架还能赋能社区能源管理,例如,在保障隐私的前提下,聚合社区内可再生能源发电与柔性负荷数据,优化本地微网运行策略,促进绿电就地消纳,助力构建绿色低碳的智慧社区。

#### 6 结语

本文针对传统“端-云”架构在智能电表实时用电行为分析中面临的挑战,提出并实现了一种基于边缘计算的创新解决方案。通过构建“端-边-云”协同架构,并在边缘侧部署轻量化的深度学习模型,我们的方法成功地在保证分析精度的同时,显著降低了通信开销与系统延迟,并通过差分隐私机制有效保护了用户数据隐私。未来的研究工作将从以下几个方向展开:(1)探索更高效的模型压缩与自适应推理技术,以支持更多种类的电器分解;(2)研究多边缘节点间的联邦学习机制,实现无需原始数据交换的协同模型进化;(3)将边缘智能分析能力与区块链技术结合,构建可信、可追溯的用电数据共享与交易生态;(4)深入研究用电行为与用户社会经济属性、心理因素的关联,提供更具人文关怀的能源服务。

#### 参考文献

- [1]范宇.基于智能电表数据的用户用电行为挖掘及电力负荷预测算法研究[D].吉林大学,2024.DOI:10.27162/d.cnki.gjlin.2024.003725.
- [2]邓欣宇.基于智能电表数据和深度学习的居民用电行为聚类分析及负荷预测方法研究[D].天津大学,2020.DOI:10.27356/d.cnki.gtjdu.2020.003280.
- [3]刘宗征,盛昕炜.基于多源数据融合的智能电表异常用电行为识别方法[J].数字技术与应用,2025,43(11):6-8.
- [4]费珂.基于智能电表信息的窃电行为识别方法研究[D].重庆大学,2021.DOI:10.27670/d.cnki.gcqdu.2021.004230.