

基于联邦学习和边缘计算的电能质量扰动 分类方法研究

吴志超^{1*}, 姚勇¹, 王义国², 林峰³, 孟祥宇⁴, 胡轲珽⁴

(1. 广东能源集团科学技术研究院有限公司, 广东 广州 510620;

2. 广东省能源集团有限公司, 广东 广州 510620;

3. 广东粤电青溪发电有限责任公司, 广东 梅州 514200;

4. 西南交通大学电气工程学院, 四川 成都 611756)

Research on Power Quality Disturbance Classification Method Based on Federated Learning and Edge Computing

WU Zhichao^{1*}, YAO Yong¹, WANG Yigu², LIN Feng³, MENG Xiangyu⁴, HU Keting⁴

(1. Guangdong Energy Group Science and Technology Research Institute Co., Ltd.,

Guangzhou 510620, China;

2. Guangdong Energy Group Co., Ltd., Guangzhou 510620, China;

3. Guangdong Yuedian Qingxi Power Generation Co., Ltd., Meizhou 514200, China;

4. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: [Objective] With the rapid development of modern power grids, power quality issues have become significant concerns in power systems. These issues, including voltage fluctuations, harmonics, transient pulses, and voltage interruptions, not only affect the safe operation of power systems but can also lead to equipment damage and energy waste. To address the limitations of traditional power quality classification methods, which suffer from poor recognition performance, high computational complexity, and data privacy concerns, this paper proposed a federated weighted resampling and hybrid optimization (FedWRHO) algorithm, which leverages federated learning and edge computing. [Method] First, a hybrid model integrating convolutional neural network (CNN) and long short-term memory (LSTM) network was designed to efficiently extract spatiotemporal features of power quality signals, with local training performed on edge devices. Subsequently, a distributed federated learning framework was established by integrating edge computing with federated learning, allowing edge nodes to utilize local data for training while aggregating models in the cloud to improve overall model performance. Finally, detailed experimental validation was

conducted to assess the effectiveness of the proposed FedWRHO algorithm and its hybrid CNN-LSTM model.

[Results] The findings indicated that the model achieved high classification accuracy for 14 types of power signals, with most categories reaching or exceeding 95% accuracy. Additionally, the data transmission volume and storage requirements for edge training were significantly lower than those for centralized training. [Conclusion] The method proposed in this paper not only demonstrates superior classification performance and data privacy protection but also effectively addresses issues related to computational resource allocation and adaptability, indicating broad application potential.

Key words: power quality; edge computing; federated learning; convolutional neural network; long short-term memory network

摘要: [目的]随着现代电网的快速发展,电能质量问题不可忽视,其不仅影响电力系统的安全运行,还可能导致设备损坏和电能浪费。针对传统的电能质量分类方法存在识别效果差、计算复杂度高和数据隐私问题,本文提出了一种结合联邦学习和边缘计算的联邦加权重采样与混合优化(FedWRHO)算法。[方法]首先,设计了一种结合卷积神经网络(CNN)和长短期记忆(LSTM)网络的混合模型,以高效提取电能质量信号的时空特征,并在边缘

基金项目: 国家青年科学基金项目(52102477)

Young Scientists Fund of the National Natural Science Foundation of China (52102477)

设备上进行本地训练。然后,将边缘计算与联邦学习相结合,设计了一个分布式的联邦学习框架,使各边缘节点利用本地数据进行训练,并在云端聚合模型,提高整体分类性能。最后,为了验证所提的 FedWRHO 算法及其结合 CNN-LSTM 的混合模型的有效性,进行了详细的试验验证。【结果】结果表明,模型对 14 类电能信号的分类准确率较高,大多数类别的准确率接近或超过 95%;边缘训练的数据传输量和存储需求显著低于集中训练。【结论】本文所提方法,不仅在分类性能和数据隐私保护方面表现优越,还解决了计算资源分配和适应性方面的问题,具有广泛的应用前景。

关键词: 电能质量; 边缘计算; 联邦学习; 卷积神经网络; 长短期记忆网络

0 引言

随着现代电网的快速发展和广泛应用,电能质量成为电力系统中不可忽视的重要问题。图 1 展示了一个现代电网的综合电力系统结构,包括火力发电站、公共电网、新能源发电站、并网逆变器、集中式变电站和非线性负载等组件。电能质量问题主要包括电压波动、谐波、暂态脉冲和电压中断等^[1],这些问题不仅影响电力系统的安全运行,还可能导致电气设备的损坏和电能浪费。因此,快速准确地辨识电能质量扰动对于保障电力系统的可靠性和稳定性具有重要意义。

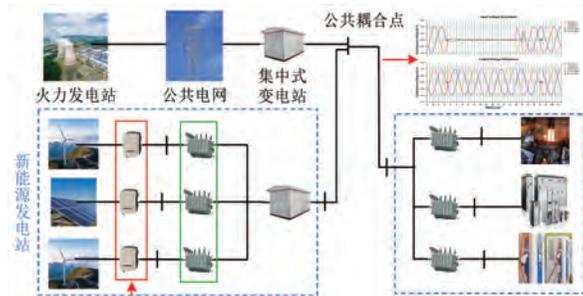


图 1 考虑新能源电站与大功率负荷接入下的电力系统
Fig. 1 Integration of renewable energy power stations and high-power loads in power system

目前,电能质量分类方法主要包括统计分析、信号处理和机器学习方法^[2]。统计分析方法通过分析电能质量数据的统计特征来进行分类,具有实现简单、计算量小的优点,但对于复杂扰动信号的识别效果较差^[3]。信号处理方法如小波变换和傅里叶变换^[4],可以有效提取电能质量信号的特征,但在实际应用中受限于计算复杂度和实时性。机

器学习方法近年来发展迅速,尤其是深度学习技术在电能质量分类中表现出较高的准确率和鲁棒性^[5]。然而,传统的机器学习方法通常依赖于大量集中式的数据训练,这不仅带来数据隐私和安全问题,还需要较高的计算资源和带宽支持。此外,随着配电网规模的扩大和设备的多样化,中心化方法难以适应复杂多变的电能质量扰动信号。因此,如何在保证数据隐私和安全的前提下,有效地进行电能质量扰动信号的分类和辨识,成为亟待解决的问题。

边缘计算作为一种新兴的计算模式,将计算任务分散到网络边缘的设备上以减少数据传输延迟和带宽占用,增强数据隐私保护。在电能质量分类中,边缘计算可以充分利用分布式电力设备的计算资源,实现本地数据的实时处理和分析^[6]。常见的边缘计算方法包括移动边缘计算^[7]、雾计算^[8]和边缘智能^[9]等。其中,联邦学习作为一种分布式机器学习方法,可以在保护数据隐私的前提下,实现跨设备的协同训练和模型优化。联邦学习通过在每个边缘设备上进行本地模型训练^[10],并将模型参数上传至中央服务器进行聚合,从而构建出全局模型。这种方法不仅能有效减少数据传输量,保护用户隐私,还能提高模型的泛化能力和准确性。

基于联邦学习的框架能够很好地解决中心化方法的缺陷。在联邦学习中,数据始终保留在本地,只有模型参数在设备之间传输,大大减少了数据传输量,降低了隐私泄露的风险^[11]。在配电网中,边缘设备如智能电表和分布式能源设备可以利用本地数据进行模型训练,并通过联邦学习将模型参数上传至云端进行聚合和优化,生成全局模型,再下发至各个边缘设备进行部署^[12]。这样一来,既保证了模型的高效性和准确性,又保护了用户数据的隐私。

近年来,联邦学习和边缘计算在电能质量分类中的应用研究逐渐增多。联邦学习能够解决传统集中式训练模式中的数据隐私问题,同时减少网络传输带宽的需求。通过在边缘设备上进行本地模型训练,边缘计算可以实时处理电能质量数据,提高分类的响应速度和准确性^[13]。然而,当前的研究也面临一些挑战和问题。例如,边缘设备的计算能力和存储资源有限,可能无法处理复

杂的深度学习模型^[14]。此外,边缘设备之间的数据质量和数量存在差异,如何有效聚合异构数据成为难题^[15]。在联邦学习过程中,不同设备的参与频率和数据分布不均衡,可能导致全局模型的性能下降^[16]。

为解决上述问题,本文提出了一种联邦加权重采样与混合优化(Federated Weighted Resampling and Hybrid Optimization, FedWRHO)算法用于联邦学习客户端模型训练过程,解决了边缘计算平台扰动数据样本不平衡和数据异构问题。此外,设计了一种结合卷积神经网络(Convolutional Neural Network, CNN)和长短期记忆(Long Short-Term Memory, LSTM)网络的混合模型,能够高效提取电能质量信号的时空特征,并在边缘设备上进行本地训练。通过边缘计算与联邦学习相结合,解决了传统中心化方法在数据隐私、计算资源分配和适应性等方面的不足。具体来说,本研究设计了一个分布式的联邦学习框架,使得各个边缘节点能够充分利用本地数据进行训练,同时在云端进行模型聚合,从而提高整体模型的性能。最后,本文还针对不同类型的电能质量扰动信号进行了试验验证,证明了所提出方法的有效性和优越性。

1 联邦学习模型

1.1 联邦学习

传统的机器学习和深度学习方法通常依赖于集中式的数据处理,需要将大量数据汇集到一个中央服务器进行训练,这不仅会带来数据传输和

存储的压力,还存在数据隐私和安全性问题。联邦学习通过将模型训练分散到多个边缘服务器上,有效地解决了这些问题。

图2展示了联邦学习过程中的参数更新和聚合机制。图中包含多个客户端和一个中央服务器,每个客户端拥有本地数据集,并在本地数据集上进行模型训练。联邦学习的过程从服务器向各个客户端发送聚合后的全局模型参数开始,客户端接收到这些参数后,利用本地数据进行模型更新;更新后的模型参数主要包括浅层参数和深层参数,在训练过程中,各个客户端利用本地数据对模型进行更新,并将更新后的浅层参数发送回中央服务器,深层参数则保留在本地;中央服务器接收到来自各个客户端的浅层参数后,进行参数聚合,这个聚合过程通过结合所有客户端的浅层参数,生成一个新的全局模型参数;然后,中央服务器更新全局模型,将新的全局模型参数再次发送给各个客户端。这个循环不断重复,直到模型收敛或达到预设的训练轮次。在这个过程中,各个客户端的本地数据始终保留在本地,避免了数据隐私泄露。可见,联邦学习能够在保护数据隐私的前提下利用分布式数据进行有效的模型训练。

通过通信设备进行参数传输的过程,强调了各个客户端之间的数据隔离,确保数据在整个训练过程中不会被直接交换或暴露。联邦学习通过这种分布式的训练方式,有效地保护了数据隐私,同时实现了模型的协同优化。

在边缘计算环境中,数据往往具有异质性,即

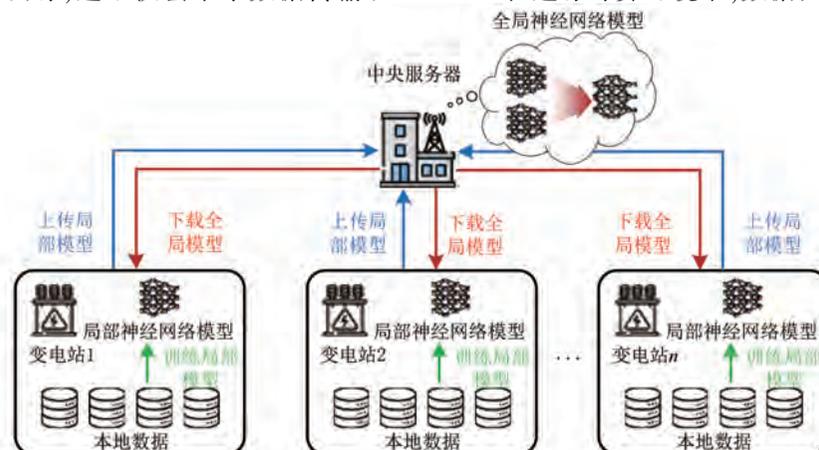


图2 联邦学习算法的训练过程

Fig. 2 Training process of federated learning algorithms

不同边缘设备上的数据分布和质量可能存在显著差异。此外,数据样本的数量也可能不均衡,有些设备可能采集了大量数据,而另一些设备的数据量则相对较少。这些问题会影响传统联邦学习算法的效果,使得模型在全局聚合时可能偏向于某些设备的数据,从而影响整体模型的泛化能力和准确性。

为解决上述问题,本文提出 FedWRHO 算法。通过引入数据加权、样本重采样和混合优化的机制,有效解决了这些问题。具体步骤如下。

步骤 1: 初始化全局模型

在 FedWRHO 算法的初始化过程中,所有边缘设备和服务器首先需要进行环境准备,包括确保所有设备和服务器处于正常工作状态并连接到网络,安装必要的软件如深度学习框架和联邦学习库,以及配置 Python 环境和相关库。然后,在每个边缘设备上定义相同的神经网络模型架构,并使用相同的随机种子初始化模型参数,确保初始模型参数一致。其次,设定学习率、调节参数和其他超参数,如批量大小、本地训练轮数以及全局训练轮数。这些超参数根据实际应用场景进行选择和调整,以达到最佳性能。在数据准备阶段,每个边缘设备根据实际情况对数据进行预处理,例如标准化或归一化处理,以保证数据在模型训练过程中的稳定性和一致性。

步骤 2: 数据加权和样本重采样

对于数据加权和样本重采样,每个边缘设备根据其数据质量和数据量计算加权系数。数据质量权重通过设备的数据噪声水平计算,而数据量权重则基于设备的数据量计算。

数据质量权重可以通过式(1)获得:

$$\gamma_i = \frac{1}{\text{Noise Level}_i + \varepsilon} \quad (1)$$

式中:Noise Level_{*i*} 为设备 *i* 的数据噪声水平; ε 为防止除零的一个小常数。

数据量权重 δ_i 通过式(2)获得:

$$\delta_i = \frac{\text{Data Size}_i}{\max(\text{Data Size})} \quad (2)$$

式中:Data Size_{*i*} 为设备 *i* 的数据量。

重采样是为了平衡各类数据的分布,可以通过过采样较少类别的数据或欠采样较多类别的数据来实现。在重采样过程中,根据权重对数据集

D_k 进行加权重采样。具体如下。

1) 根据数据质量和数据量的加权系数,计算综合权重 $\alpha_i = \gamma_i \cdot \delta_i$ 。每个数据样本的综合权重 α_i 计算完成后,通过归一化处理得到 α'_i ,使权重之和为 1。

2) 累积分布函数 (Cumulative Distribution Function, CDF): 基于归一化后的权重构建 CDF。CDF 是一个单调递增的函数,用于指导重采样,其表达式为

$$CDF_i = \sum_{j=1}^i \alpha'_j \quad (3)$$

3) 随机采样: 生成一个均匀分布的随机数 $r \in [0, 1)$ 。对于每个随机数 r ,在 CDF 上查找相应的数据样本 x_i 。

4) 重采样数据集: 重复上述步骤多次,构建新的重采样数据集 D'_k 。

步骤 3: 本地训练

每个边缘设备使用重采样后的数据进行本地训练,使用 Adam 优化器更新模型参数,如式(4)所示:

$$\omega_{t+1}^i = \omega_t^i - \eta \cdot \text{Adam}[\nabla L_i(\omega_t^i)] \quad (4)$$

式中: ω_t^i 为边缘设备 *i* 在第 *t* 轮的模型参数; η 为学习率; $\nabla L_i(\omega_t^i)$ 为损失函数 L_i 对模型参数 ω_t^i 的梯度;Adam 为 Adam 优化器,用于调整梯度的计算。

步骤 4: 参数上传

每个边缘设备将更新后的本地模型参数 ω_{t+1}^i 上传到云端服务器。

步骤 5: 全局聚合

服务器根据加权计算式计算每个设备的权重 α_i ,如式(5)所示:

$$\alpha_i = Q_{i0}^{k_1} \cdot N_{i0}^{k_2} \quad (5)$$

式中: Q_{i0} 为数据质量权重; N_{i0} 为数据量权重; k_1 为数据质量权重的调整参数; k_2 为数据量权重的调整参数。

数据质量权重通常基于每个设备的数据准确性、一致性和完整性等质量指标进行计算。假设有 n 个设备,每个设备的数据质量得分为 Q_i ,则可以标准化这些得分以得到权重:

$$Q_{i0} = \frac{Q_i}{\sum_{j=1}^n Q_j} \quad (6)$$

数据量权重通常基于每个设备上的数据样

本数计算。假设有 n 个设备,每个设备的数据样本数为 N_i ,则可以标准化这些样本数以得到权重:

$$N_{io} = \frac{N_i}{\sum_{j=1}^n N_j} \quad (7)$$

进而,服务器使用加权随机梯度下降(Stochastic Gradient Descent, SGD)进行全局参数更新,得到新的全局模型参数:

$$\omega_{t+1} = \omega_t - \eta \cdot \frac{1}{K} \sum_{i=1}^K \alpha_i \cdot \nabla L_i(\omega_t^i) \quad (8)$$

式中: K 为参与训练的边缘设备数量; ω_{t+1} 为新的全局模型参数。

步骤6:模型分发

服务器将更新后的全局模型参数 ω_{t+1} 分发各边缘设备。

步骤7:条件判断

重复步骤2~步骤6,直到满足终止条件。

通过这样的联邦学习过程,数据隐私得到了保护,同时模型可以在多个分散的数据源上进行训练,提高了模型的泛化能力。

1.2 联邦学习算法对比

将 FedWRHO 算法与联邦平均(Federated Averaging, FedAvg)算法^[17]、联邦随机梯度下降(Federated SGD, FedSGD)算法^[18]以及联邦近端优化(Federated Proximal Optimization, FedProx)算法^[19]进行对比,如表1所示。

表1 联邦学习算法对比

Tab. 1 Comparison of federated learning algorithms

指标名称	算法名称			
	FedAvg	FedSGD	FedProx	FedWRHO
通信效率	高,每轮次只需上传模型参数	低,需要频繁上传梯度	高,每轮次只需上传模型参数	高,每轮次只需上传模型参数
计算复杂度	低,每轮次进行一次本地训练并上传参数	高,每轮次进行一次本地梯度计算并上传梯度	高,需要在本地计算中增加正则项	中,结合本地 Adam 和全局 SGD 优化
数据异质性处理能力	差,易受数据分布不均影响	差,易受数据分布不均影响	好,通过正则项缓解数据异质性问题	优,通过数据加权和样本重采样处理数据异质性
样本不平衡处理能力	差,对样本不平衡无处理机制	差,对样本不平衡无处理机制	一般,通过正则项间接处理样本不平衡	优,通过样本重采样直接处理样本不平衡
收敛速度	慢,需要多轮次进行聚合	快,由于频繁更新,能更快收敛	适中,依赖正则项调节收敛	快,结合本地和全局优化,提高收敛速度
模型精度	中,易受数据分布和本地训练时间影响	高,由于频繁更新,精度较高	高,通过正则项改进精度	高,通过混合优化和数据加权,提升模型精度
鲁棒性	差,对设备失效和数据异质性敏感	差,对设备失效和数据异质性敏感	好,正则项增强模型对数据异质性的鲁棒性	优,通过多种机制提升对数据异质性和失效的鲁棒性
实现难度	低,算法简单,易于实现	高,实现复杂,需频繁通信	高,需实现正则项,增加了实现复杂度	中,结合多种机制,实现难度适中

由表1可知,FedWRHO在结合多种机制的情况下,虽然实现难度适中,相对复杂度有所增加,但这些复杂性带来了显著的性能提升。与其他联邦学习算法相比,FedWRHO通过数据加权、样本重采样和混合优化,解决了边缘计算平台扰动数据样本不平衡和数据异构问题,优化了客户端模型的训练过程,在通信效率、计算复杂度、数据异质性处理能力、样本不平衡处理能力、收敛速度、模型精度和鲁棒性等方面表现出色,适用于电能

质量监测等复杂数据环境。

2 边缘计算模型

2.1 卷积长短期记忆网络

在联邦学习环境中,卷积长短期记忆网络(CNN-LSTM)模型结合了CNN和LSTM的优势,适用于处理电流波形等时序数据的电能质量扰动分类任务,能够有效地提取和利用时间特征,提高分类的准确性和鲁棒性。

CNN-LSTM 结构如图 3 所示,其输入数据是一系列时间步长的特征。首先通过卷积层进行处理,卷积层使用 1 维卷积核,卷积核大小为 1, padding 方式为“valid”,并使用 32 个滤波器,激活函数为 ReLU。卷积层的作用是提取输入数据的局部特征,通过滑动窗口进行卷积操作,输出特征图。

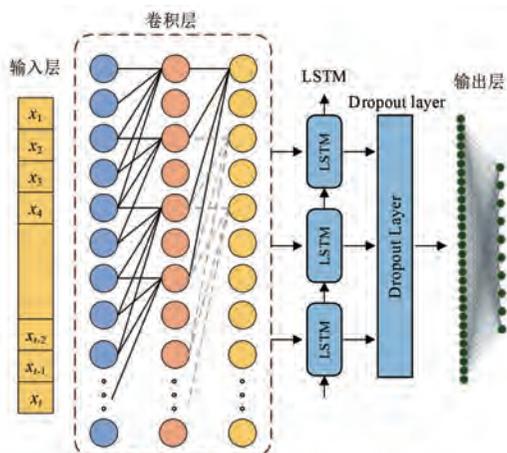


图 3 CNN-LSTM 结构

Fig. 3 CNN-LSTM architecture

接着,卷积层输出的特征图传递到第一个 LSTM 层。第一个 LSTM 层有 50 个单元,用于处理卷积层输出的特征,捕捉数据中的时间依赖关系。LSTM 层之后紧跟一个 Dropout 层,丢弃率为 50%。Dropout 层在训练过程中随机丢弃一部分神经元,以防止过拟合,增强模型的泛化能力。

然后,经过 Dropout 层处理的特征传递到第二个 LSTM 层,第二个 LSTM 层有 32 个单元,进一步处理时间特征,提升模型的时间建模能力。第二个 LSTM 层的输出再经过另一个 Dropout 层,同样丢弃率为 50%,进一步防止过拟合。

最后,经过 Dropout 层处理后的特征传递到全连接层。全连接层有 25 个单元,使用 Softmax 激活函数,将 LSTM 层提取的特征映射到最终的分类型结果,输出每个类别的概率。

2.2 基于联邦学习的边缘计算框架

图 4 为基于边缘计算与联邦学习的电能质量扰动实时监测与模型优化框架。该框架结合了分布式机器学习和边缘计算的优势,可以在保护数据隐私的同时进行高效的模型训练和部署。

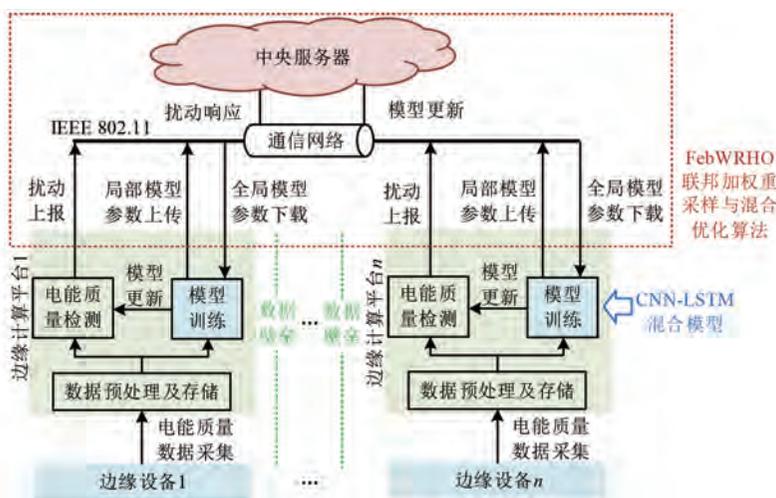


图 4 基于边缘计算与联邦学习的电能质量扰动实时监测与模型优化框架

Fig. 4 Real-time monitoring and model optimization framework for power quality disturbance based on edge computing and federated learning

由云端服务器初始化一个专门用于电能质量扰动分类的 CNN-LSTM 模型。模型初始化后,云端服务器将模型参数分发到各个边缘设备,包括智能电表、传感器和其他收集电流波形数据的终端设备。

边缘设备接收到初始模型参数后,开始利用本地存储的电流波形数据进行模型训练。CNN-

LSTM 模型的卷积层首先对输入的电流波形进行一维卷积操作,提取局部时序特征;随后通过池化层进行下采样,减少特征图的维度;接着,LSTM 层处理池化后的特征图,捕捉电流波形的长时间依赖关系;最终,通过全连接层将提取的特征映射到分类空间,实现电能质量扰动的分类。在本地训练完成后,边缘设备将更新后的模型参数发送

到云端服务器。

云端服务器接收到来自多个边缘设备的模型参数后,使用 FedWRHO 算法进行聚合。

聚合后的全局模型参数再次下发到各边缘设备,更新其本地模型,进入下一轮的本地训练和聚合过程。这种迭代过程持续进行,直到模型在电能质量扰动分类任务上达到预期的精度或达到预定的训练轮数。

通过这种联邦学习的边缘计算框架,电能质量扰动的识别和分类任务能够在分布式环境中高效完成。边缘设备利用本地数据进行模型训练和部署,在实际应用场景中实时识别和分类电能质量扰动事件,提高了系统的响应速度和精度。而云端服务器通过聚合各边缘设备的知识,不断优化和提升全局模型的性能,形成了一个高效、协同的分布式学习系统。

2.3 模型训练与通信需求

在现场工程应用中,电能质量监测和分类需要在有限的计算存储能力下实现高效的训练和样本的更新迭代,同时必须满足严格的通信标准和实时性要求。为确保系统在复杂电力环境中的稳定运行,提出了一套全面的通信方案和实现方法。根据通信标准,边缘设备与云服务器之间的无线数据传输采用 IEEE 802.11 系列无线通信标准(如 Wi-Fi 6)以获得更高的数据传输速率和更低的延迟。在有线通信方面,使用 IEEE 802.3 标准(如千兆以太网),以保证在高带宽和高稳定性需求的环境中实现可靠的数据传输。实际中,边缘设备通过局域网与云服务器保持通信,以确保高效的数据传输和系统同步;对于移动式监测设备,则采用长期演进(Long Term Evolution, LTE)或 5G 网络作为补充,确保设备在移动状态下也能进行实时数据传输。为了减少通信延迟和带宽消耗,边缘设备在本地进行特征提取和初步分类,仅将处理后的数据传输至云服务器,降低了通信成本。

在现场工程应用的配置方面,电能质量采集装置被安装在电动汽车充电站、光伏电站、风电场和变电站等关键位置。这些装置配备了嵌入式计算平台,用于实时数据处理和初步分类。在大型工业应用中,建议配备高性能的有线网络设施,如光纤连接,以确保数据能够快速、安全地传输至云端进行进一步分析;在居民区或小型应用中,则可

依赖 Wi-Fi 6 和 5G 等无线通信技术。应用过程中,边缘设备通过嵌入式平台的计算能力进行实时电能质量数据采集与处理,完成分类结果和关键特征信息后,通过 Wi-Fi 或以太网传输至云服务器。云服务器接收到边缘设备的数据后,进行深度分析和模型训练,并将优化后的模型更新下发至边缘设备,以提升实时分类能力。

为了验证边缘计算设备的适用性,本文选择了多种不同类型的边缘设备进行试验,并根据不同应用场景的需求进行了设备选型。试验中使用的设备类型包括在线监测平台、移动计算平台和云计算平台,每种设备的处理器、图形处理器、随机存取存储器以及存储空间等关键参数均有所不同,以此满足从实时监测到大规模模型训练的不同需求。这种配置确保了边缘计算设备在各种电能质量扰动分类任务中的高效性和可靠性。

3 算例分析

为了验证所提的 FedWRHO 算法及其结合 CNN-LSTM 的混合模型的有效性,进行了详细的试验。试验不仅使用了仿真数据,还引入了实际工程现场的数据,以全面评估算法在实际应用中的表现。

3.1 仿真电能质量扰动数据集

从电力系统仿真软件中获取用于电能质量扰动分类的数据集。仿真数据符合 IEEE-1159 标准,模拟常见的电能质量扰动信号。仿真中,采样周期 $N=10$,采样频率为 6.4 kHz,每个扰动信号包含 1 280 个采样点。通过仿真生成 7 种单一扰动信号、6 种复合扰动信号以及正常信号,共 14 种信号。部分事故期间的电压波形信号如图 5 所示。

3.2 实测电能质量扰动数据集

为进一步验证算法的有效性,试验中还引入了实际工程现场的数据集。这些数据集采集自广东梅州大埔青溪电厂的多个变电站,数据采集时间从 2021 年 6 月至 2022 年 7 月。采集的数据涵盖了多个典型扰动事件,包括变压器投切、大型负荷启动、无功补偿设备投切、雷击、电动汽车充电期间的电压暂降以及电网设备故障引发的谐波失真和三相不平衡等。采样频率设置为每周期 512 个采样点,采样时长为 0.3 s。通过这些样本,进

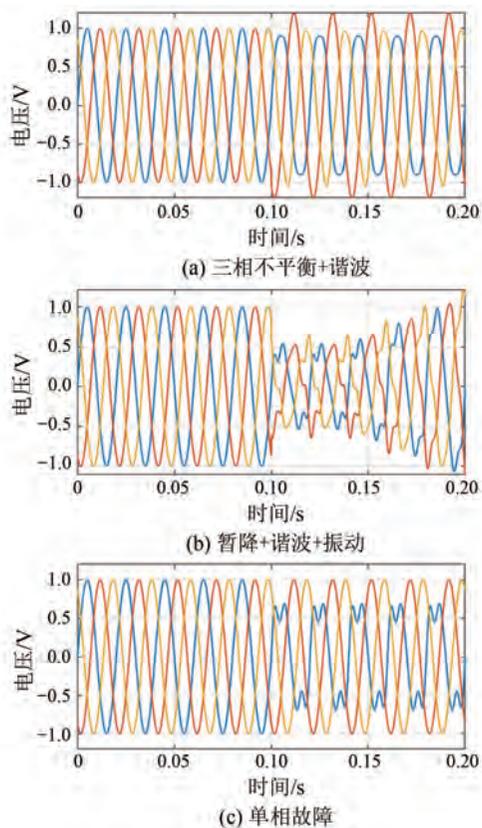


图 5 不同事故期间的电压波形信号

Fig. 5 Voltage waveform signals during different incidents

一步验证 FedWRHO 算法和 CNN-LSTM 混合模型在实际应用场景中的分类准确性和鲁棒性。

在这些设备的工作流程中,首先通过集成传感器实时采集电能质量信号,这些信号以 10 kHz 以上的高频率进行记录,确保捕捉到扰动事件的完整性。采集到的数据随后在本地进行预处理,经过去噪和特征提取后,输入到 CNN-LSTM 模型中进行扰动分类。边缘设备利用 FedWRHO 算法在本地进行模型训练和更新,最终将更新后的模型参数上传至中央服务器,中央服务器再通过模型聚合与优化,将全局模型下发至各个边缘设备。

为了确保边缘设备能够满足电能质量扰动分类任务的需求,试验选择了多种不同类型的边缘设备进行测试,以便在不同应用场景下选择合适的设备。

无论是仿真数据还是实际采集数据,都需要进行预处理以确保数据质量和一致性。预处理包括去噪、标准化和特征提取等步骤。采集或仿真得到的原始数据要整理为适合模型训练的格式,如将每个扰动信号的 1 280 个采样点按时间步长

重塑为 10 个周期,每周期 128 个点。

预处理后,为每个扰动信号样本添加相应的标签,标识其类型(如 C1 至 C14),并确保数据集的样本均匀分布,每类扰动信号样本数量相同,避免数据不平衡问题。然后,按照 7:3 的比例将数据集划分为训练集和测试集,以便进行模型训练和性能评估。

用于评估模型的精度和识别能力的指标主要有准确率(Precision, Pre)、召回率(Recall, Rec)和 F1 分数(F1 Score, F1)。Pre 表示模型在预测为正类的样本中实际正确的比例,其计算式为 $Pre = [TP / (TP + FP)] \times 100\%$,其中 TP 为正确预测为正类的样本数量,FP 为错误预测为正类的样本数量。Rec 表示模型在所有实际为正类的样本中成功识别为正类的比例,计算式为 $Rec = [TP / (TP + FN)] \times 100\%$,其中, FN 为错误预测为负类的正类样本数量。F1 是准确率和召回率的调和平均值,用于综合评估模型性能,计算式为 $F1 = 2(Pre \times Rec) / (Pre + Rec) \times 100\%$ 。这些指标共同帮助评估模型的精度和识别能力。CNN-LSTM 模型对于不同电能质量信号的分类结果如表 2 所示。

3.3 边缘计算分类结果可视化分析

CNN-LSTM 模型分类结果的混淆矩阵如图 6 所示。图中横轴表示模型预测的类别,纵轴表示真实的类别。类别 C1 到 C13 分别代表通过仿真生成的 7 种单一扰动信号和 6 种复合扰动信号,C14 代表正常信号。

真实集	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	
C1	99	0	0	0	0	0	0	0	0	0	0	0	0	1	
C2	0	98	0	1	0	0	0	1	0	0	0	0	0	0	
C3	0	0	98	1	1	0	0	0	0	0	0	0	0	0	
C4	0	0	0	98	0	0	0	0	0	0	0	0	0	2	
C5	0	0	0	1	97	0	0	0	2	0	0	0	0	0	
C6	0	0	0	2	0	98	0	0	0	0	0	0	0	0	
C7	2	0	0	0	0	0	98	0	0	0	0	0	0	0	
C8	0	0	0	0	0	0	0	100	0	0	0	0	0	0	
C9	0	0	0	0	0	0	0	0	98	0	0	0	0	1	
C10	0	0	0	0	0	0	1	0	0	98	0	0	0	0	
C11	0	0	0	0	0	2	0	0	0	1	97	0	0	0	
C12	0	0	0	0	0	0	0	0	0	0	0	100	0	0	
C13	2	0	0	0	0	0	0	0	0	0	0	0	98	0	
C14	0	0	0	0	0	0	0	0	0	0	0	0	3	97	
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14

图 6 CNN-LSTM 模型的分类结果图

Fig. 6 Classification results of the CNN-LSTM model

表 2 CNN-LSTM 模型的分类结果

Tab.2 Classification results of the CNN-LSTM model

类别	分类结果/%		
	Pre	Rec	F1
C1	97.50	95.00	96.23
C2	95.40	94.20	94.80
C3	98.20	97.00	97.59
C4	96.70	96.20	96.45
C5	97.10	95.60	96.34
C6	99.00	98.50	98.75
C7	96.00	94.50	95.24
C8	95.80	95.00	95.39
C9	96.20	95.50	95.84
C10	97.80	96.90	97.34
C11	94.50	93.00	93.74
C12	95.60	94.80	95.19
C13	96.10	95.50	95.79
C14	97.50	96.50	97.00
C1+C2	95.60	94.80	95.19
C1+C3	96.00	95.00	95.49
C1+C4	95.40	94.20	94.80
C1+C5	97.20	95.80	96.49
C1+C6	98.00	97.50	97.75
C2+C3	95.50	94.70	95.09
C2+C4	95.80	95.00	95.39
C2+C5	97.10	95.60	96.34
C2+C6	99.00	98.50	98.75
C3+C4	96.00	94.50	95.24
C3+C5	97.50	95.50	96.49
C3+C6	98.00	97.50	97.75
C4+C5	95.60	94.80	95.19
C4+C6	99.00	98.50	98.75
C5+C6	98.20	97.00	97.59
C1+C7	96.20	95.50	95.84
C2+C7	94.50	93.00	93.74
C3+C7	95.60	94.80	95.19
C4+C7	97.50	96.50	97.00

由图 6 可知,模型对 14 种电能信号的分类表现总体良好,大多数类别的对角线元素接近或超过 95,表明模型具有较高的准确率。

为进一步验证本文所提 CNN-LSTM 模型的优越性,将 CNN Localized Learning、CNN Centralized Learning、CNN-LSTM Centralized Learning 以及 CNN-LSTM Federated Learning 进行对比分析,结果如图 7 所示。由图 7 可知,CNN Localized Learning 在所有训练样本比例下的分类准确度相对较低,随着训练样本比例的增加,分类准确度逐渐提高;CNN Centralized Learning 的分类准确度高于 CNN Localized Learning,表明集中学习方法能更好地利用训练数据;CNN-LSTM

Centralized Learning 的分类准确度最高,表明卷积神经网络结合长短期记忆网络能显著提高分类性能;CNN-LSTM Federated Learning 的分类准确度接近于 CNN-LSTM Centralized Learning,表明联邦学习在保持高分类准确度的同时能够保护数据隐私。

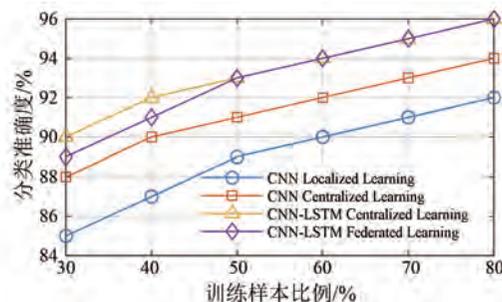


图 7 不同训练样本比例下不同模型分类准确度

Fig.7 Classification accuracy of different models under different training sample proportions

3.4 联邦学习算法效果对比分析

图 8 为集中训练和边缘训练两种训练模式在云端所需的存储空间和模型传输数据量的对比。通过对比可以看出,边缘训练的数据传输量远低于集中训练,这是因为边缘训练仅需传输模型参数而集中训练需要传输整个数据集,这种差异使得边缘训练在网络带宽和传输时间方面更具优势;边缘训练的存储需求也远低于集中训练,这是因为边缘训练只需存储模型参数而集中训练需要存储整个数据集,这种差异使得边缘训练在云端存储资源的占用方面更为节省,适用于存储空间有限的应用场景。

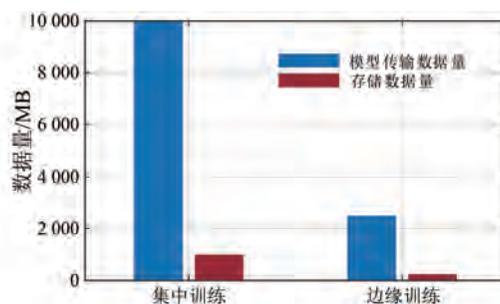


图 8 不同训练模式所需数据量对比

Fig.8 Comparison of data requirements for different training modes

在实际应用中,选择哪种训练模式需要综合考虑多方面因素,包括数据隐私、网络带宽、存储资源和计算资源等。边缘训练适用于数据分布在

多个设备且需要保护数据隐私的场景,同时还能显著减少云端存储和传输开销;集中训练则适用于数据可以集中收集且网络和存储资源充足的场景。

4 结语

本文提出了一种基于联邦加权重采样与混合优化算法的电能质量扰动分类方法。结合边缘计算和联邦学习,有效解决了传统中心化方法在数据隐私、计算资源分配和适应性方面的不足。通过试验验证,本文得出了以下结论。

(1) 本文所提出的分类方法采用了结合 CNN 和 LSTM 的混合模型,能够高效提取电能质量信号的时空特征,显著提高了分类准确性。混淆矩阵分析结果显示,模型对 14 种电能信号的分类准确率较高,大多数类别的准确率接近或超过 95%。

(2) 联邦学习框架通过使数据始终保留在本地,仅在设备之间传输模型参数,显著减少了数据传输量,降低了隐私泄露的风险。在保证分类准确度的同时,有效保护了用户数据的隐私。边缘计算和联邦学习相结合,通过分散计算任务至网络边缘设备,减少了云端的存储需求和模型传输数据量,显著优化了资源利用,适用于存储空间和网络带宽有限的应用场景。

(3) 通过使用电力系统仿真软件生成的仿真数据和电能质量监测设备采集的实际数据,验证了所提出方法的有效性和优越性。预处理后的高质量数据集支持模型的训练和性能评估,进一步证明了该方法在分类性能和数据隐私保护方面的优越性。

总体而言,本文所提的基于联邦加权重采样与混合优化算法的电能质量扰动分类方法,不仅在分类性能和数据隐私保护方面表现优越,还显著优化了资源利用,具有广泛的应用前景。未来的研究可以进一步优化算法和模型,提升分类性能,并探索在更大规模和更多样化的电力系统中的应用。

参考文献

[1] 赵本强, 曾江, 谢宝平, 等. 基于光伏逆变器的电网谐波阻抗测量新技术[J]. 电机与控制应用, 2024, 51(3): 1-9.

ZHAO B Q, ZENG J, XIE B P, et al. New technology of grid harmonic impedance measurement based on photovoltaic inverter [J]. *Electric Machines & Control Application*, 2024, 51(3): 1-9.

[2] 李新旻, 陈伟, 张国政, 等. 基于高频信号耦合注入的内置式永磁同步电机转子初始位置检测方法[J]. 电机与控制应用, 2021, 48(5): 7-13.

LI X M, CHEN W, ZHANG G Z, et al. Rotor initial position detection method of IPMSM based on high frequency coupling injection [J]. *Electric Machines & Control Application*, 2021, 48(5): 7-13.

[3] 刘森, 孟静, 尹申, 等. 混合交直流主动配电网接纳裕度双重不确定性优化模型[J]. 电机与控制应用, 2023, 50(3): 88-94.

LIU M, MENG J, YIN S, et al. Dual-uncertainty optimization model for acceptance margin of hybrid AC/DC active distribution network [J]. *Electric Machines & Control Application*, 2023, 50(3): 88-94.

[4] 李智, 李长喜, 陈创庭, 等. 电流控制型储能变流器控制稳定性分析与谐波谐振抑制技术研究[J]. 电机与控制应用, 2023, 50(7): 21-34.

LI Z, LI C X, CHEN C T, et al. Control stability analysis and research on harmonic resonance suppression technology of current-control type energy storage converter [J]. *Electric Machines & Control Application*, 2023, 50(7): 21-34.

[5] 张博智, 张茹, 焦东翔, 等. 基于 VMD-SAST 的电能质量扰动分类识别方法[J]. 中国电力, 2024, 57(2): 34-40.

ZHANG B Z, ZHANG R, JIAO D X, et al. Power quality disturbance identification method based on VMD-SAST [J]. *Electric Power*, 2024, 57(2): 34-40.

[6] LIU D, LIANG H, ZENG X, et al. Edge computing application, architecture, and challenges in ubiquitous power internet of things [J]. *Frontiers in Energy Research*, 2022, 10: 850252.

[7] MACH P, BECVAR Z. Mobile edge computing: A survey on architecture and computation offloading [J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(3): 1628-1656.

[8] SHI W, CAO J, ZHANG Q, et al. Edge computing: Vision and challenges [J]. *IEEE Internet of Things Journal*, 2016, 3(5): 637-646.

- [9] SATYANARAYANAN M. The emergence of edge computing [J]. *Computer*, 2017, 50(1): 30-39.
- [10] KONECNY J, MCMAHAN H B, YU F X, et al. Federated learning: Strategies for improving communication efficiency [J]. *arXiv*, 2016, 1610.05492.
- [11] 吴彦伟, 姚刚, 王海全, 等. 基于能量共享的多微网协同优化调度[J]. *电机与控制应用*, 2024, 51(8): 1-11.
WU Y W, YAO G, WANG H Q, et al. Multi-microgrids cooperative optimal scheduling based on energy sharing [J]. *Electric Machines & Control Application*, 2024, 51(8): 1-11.
- [12] 刘晓华, 杨成月, 徐茹枝, 等. 基于强化学习的智能电网多接入边缘计算的位置隐私保护[J]. *电力信息与通信技术*, 2023, 21(1): 47-53.
LIU X H, YANG C Y, XU R Z, et al. Location privacy protection of smart grid MEC based on reinforcement learning [J]. *Electric Power Information and Communication Technology*, 2023, 21(1): 47-53.
- [13] BONAWITZ K, EICHNER H, GRIESKAMP W, et al. Towards federated learning at scale: System design [J]. *Proceedings of Machine Learning and Systems*, 2019, 1: 374-388.
- [14] VEENA C H, JITHENDAR P, ANANDHI R J, et al. Federated learning for real-time state estimation and dynamic phasor analysis in wide-area power grids [C]//2023 International Conference on Power Energy, Environment & Intelligent Control, Greater Noida, 2023.
- [15] 徐正一, 琚贇, 于轲鑫, 等. 基于联邦学习的边缘侧电能质量扰动分类研究[J]. *电力信息与通信技术*, 2023, 21(10): 26-34.
- XU Z Y, JU Y, YU K X, et al. Research on edge power quality disturbances classification based on federated learning [J]. *Electric Power Information and Communication Technology*, 2023, 21(10): 26-34.
- [16] 王鹤, 李石强, 于华楠, 等. 基于分布式压缩感知和边缘计算的配电网电能质量数据压缩存储方法[J]. *电工技术学报*, 2020, 35(21): 4553-4564.
WANG H, LI S Q, YU H N, et al. Compression acquisition method for power quality data of distribution network based on distributed compressed sensing and edge computing [J]. *Transactions of China Electrotechnical Society*, 2020, 35(21): 4553-4564.
- [17] LI X, HUANG K, YANG W, et al. On the convergence of FedAvg on non-IID data [J]. *arXiv*, 2019, 1907.02189.
- [18] BHATTI D M S, NAM H. FedCLS: Class-aware federated learning in a heterogeneous environment [J]. *IEEE Transactions on Network and Service Management*, 2023, 20(2): 1517-1528.
- [19] YUAN X, LI P. On convergence of FedProx: Local dissimilarity invariant bounds, non-smoothness and beyond [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 10752-10765.

收稿日期:2024-07-07

收到修改稿日期:2024-08-28

作者简介:

吴志超(1990-),男,硕士,高级工程师,研究方向为能源技术,wuzhichao@gdyd.com;

*通信作者:吴志超(1990-),男,硕士,高级工程师,研究方向为能源技术,wuzhichao@gdyd.com。

Research on Power Quality Disturbance Classification Method Based on Federated Learning and Edge Computing

WU Zhichao^{1*}, YAO Yong¹, WANG Yiguo², LIN Feng³, MENG Xiangyu⁴, HU Keting⁴

(1. Guangdong Energy Group Science and Technology Research Institute Co., Ltd.,

Guangzhou 510620, China;

2. Guangdong Energy Group Co., Ltd., Guangzhou 510620, China;

3. Guangdong Yuedian Qingxi Power Generation Co., Ltd., Meizhou 514200, China;

4. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China)

Key words: power quality; edge computing; federated learning; convolutional neural network; long short-term memory networks

With the rapid development and widespread application of modern power grids, power quality issues such as voltage fluctuations, harmonics, transient pulses, and voltage interruptions have become significant concerns in power systems. These power quality problems not only affect the safe operation of power systems but can also lead to equipment damage and energy waste. Traditional power quality classification methods have limitations in terms of recognition accuracy, computational complexity, and data privacy.

To address these issues, this paper proposed a federated weighted resampling and hybrid optimization algorithm, which integrated federated learning with edge computing. The algorithm was combined with convolutional neural network and long short-term memory network to efficiently extract spatiotemporal features of power quality signals, with local training performed on edge devices. A distributed federated learning framework was designed by combining edge computing and federated learning. Edge computing optimized resource utilization by reducing cloud storage requirements and data transmission for model updates. Federated

learning ensures that data remained local, significantly reducing data transmission volume and mitigating privacy risks, while maintaining high classification accuracy.

The method was further validated using simulated data generated by power system simulation software and real-world data collected by power quality monitoring devices. Experimental results showed that the method achieved high classification accuracy for various power quality disturbances, with most categories reaching or exceeding 95% recognition accuracy. The results confirmed the effectiveness and superiority of the proposed method in terms of classification performance and data privacy protection.

This study provides an effective approach for classifying power quality disturbances in modern power grids, addressing the challenges of data privacy, computational resource allocation, and adaptability associated with traditional centralized methods. Future research can further optimize the algorithm and model to improve classification performance and explore applications in larger and more diverse power systems.