

面向新型电力系统的电能质量扰动分类研究

李琮琮¹, 王清¹, 荆臻¹, 张志¹, 王平欣¹, 杨林林²
(1. 国网山东省电力公司营销服务中心(计量中心), 济南 250000;
2. 哈尔滨理工大学 测控技术与通信工程学院, 哈尔滨 150080)

摘要: 针对新型电力系统下的电能质量扰动存在信号种类复杂以及数据异构的问题, 提出一种使用联邦学习和原型学习相结合的电能质量扰动分类方法。该方法包含服务器和参与方两类工作节点, 服务器收集来自参与方的本地模型输出的本地原型。而本地原型不能被反向重构得到原始数据, 故用服务器聚合本地原型进而获得全局原型, 并发送回参与方, 以正则化本地的模型训练。相较于卷积神经网络模型, 该方法不需要大量的训练数据, 且模型不易受到轻微的异构数据扰动, 对未知的扰动信号具有较强的鲁棒性。仿真实验结果表明, 与现有方法相比, 所提出方法适用于小规模电能质量扰动样本, 分类准确率达到 0.998 3, 在新型分布式电网环境下具有较高的应用价值。

关键词: 联邦学习; 原型学习; 电能质量扰动分类; 异构数据

DOI: 10.19753/j.issn1001-1390.2025.11.013

中图分类号: TM711

文献标识码: A

文章编号: 1001-1390(2025)11-0111-09

Research on classification of power quality disturbance in novel power system

LI Congcong¹, WANG Qing¹, JING Zhen¹, ZHANG Zhi¹, WANG Pingxin¹, YANG Linlin²
(1. Marketing Service Center (Measurement Center), State Grid Shandong Electric Power Company, Jinan 250000, China. 2. School of Measurement and Communications Engineering, Harbin University of Science and Technology, Harbin 150080, China)

Abstract: Aiming at the problems of complex signal types and heterogeneous data of power quality disturbance in novel power system, a power quality disturbance classification method using Federated learning and prototype learning is proposed. This method includes two types of work nodes: server and client. The server collects the local prototype output from the local model of clients. The local prototype cannot be reverse reconstructed to get the original data. Instead, the server aggregates the local prototype to get the global prototype and sends it back to the client to regularize the local model training. Compared with the convolutional neural network model, this method does not require a lot of training data, and the model is not vulnerable to slight heterogeneous data disturbance, and has strong robustness to unknown disturbance signals. The simulation experimental results show that, compared with existing methods, the proposed method is suitable for small-scale power quality disturbance samples, with a classification accuracy of 0.998 3, which has high application value in the new distributed power grid environment.

Keywords: Federated learning, prototype learning, classification of power quality disturbances, heterogeneous data

0 引言

随着新型电力系统的不断发展,以分布式光伏、分散式风电为代表的能源大量出现,以分布式智能电网为方向的新型配电系统形态逐步成熟,形成“分布式”与“大电网”兼容并存的电网格局。智能电网产生的电力数据对于电力系统的电能质量分析、电网优化、电力系统监测和控制等尤为重要,精确的电力数据分析可以对整个电网系统更加动

态、高效地加以管理。

以分布式发电为主的新型电网并入形式^[1],具有供电设施结构紧凑,更换方便等优点,但分布式发电系统自身的机械设计和电力电子装置产生的谐波和配电网中原有的非线性负载的输出谐波交织汇集在配电网中,相比于传统配电网,含分布式发电系统的配电网谐波分布情况更加复杂多变。因此,新型电力系统下的电能质量扰动(power quality disturbance, PQD)识别成为电力工程界的热点和难点问题^[2]。

基金项目: 国网山东省电力公司科技项目(520633220001)

PQD 的类型通常表现为电压或电流的幅值、相位以及频率的突然变化或变形,包括瞬升、谐波、闪变、中断等多种扰动形式,扰动产生的原因也多种多样。为了保障电力系统安全稳定运行,需要对 PQD 的快速、智能、准确识别进行深入研究。

电能质量扰动信号识别主要有两个阶段:第一阶段,使用信号处理技术提取扰动信号的特征。传统采用信号处理的方法包括快速傅里叶变换^[3],该特征提取方法发展最为成熟,在现代电力系统中仍有使用。此外,用离散小波变换进行特征提取^[4],可以更好地解决时频分辨率不足的问题,但小波变换基函数难以选取。随后,基于经验模态分解(empirical mode decomposition, EMD)和变分模态分解(variational mode decomposition, VMD)处理电能质量信号的方法被提出^[5],但 EMD 模态混叠严重,高次谐波分解不理想,VMD 和 EMD 都存在分解层数选取困难等缺点^[6]。在提取干扰信号的特征时,上述方法容易导致特征损失,影响到分类的精度。

第二阶段是设计分类器对提取的特征进行分类。由于扰动信号大多属于非线性信号,一些新的非线性信号分析方法被引入电能质量扰动检测领域^[7]。机器学习中的支持向量机(support vector machines, SVM)具有较强的自适应学习能力,使用核函数可以解决非线性样本的分类问题^[8]。在样本类型较少且分类特征选择适当时,SVM 分类效果较好;但当样本类型较多时,部分扰动信号的波形相似,使得单一 SVM 分类准确率较低。

近年来,基于深度学习的电能质量扰动识别方法不断被提出。文献[9]提出了基于多任务学习的一维卷积神经网络模型,用来作为电能质量扰动的识别方法,在电能质量扰动识别领域展现出优势。基于卷积的神经网络采用端到端的自动识别策略为简化分类策略提供很大便利。文献[10]提出了一种基于多尺度融合选择卷积网络,以实现端到端的电能质量扰动识别分类方法,该模型由不同卷积核生成不同尺度下的特征,通过卷积神经网络来实现对单一和复合扰动成分的映射,最终选择有用的特征进行线性分类与融合。长短期记忆网络(long short-term memory, LSTM)^[11]与卷积神经网络(convolutional neural network, CNN)等深度学习网络 PQD 识别中均在取得了显著成效^[12]。这些方法避免了传统人工选择特征的主观性,能够较好地适应新型电力系统的 PQD 识别问题并达到较高的识别准确率。但目前基于卷积神经网络 CNN 的 PQD 识别方法所要求的训练样本数量过多,导致网络结构复杂,训练时间过长,且容易发生过拟合^[13]。

虽然大量的电能质量扰动检测方法已经被提出,但是在真实且复杂的环境下仍然无法应对,在复杂的电力设备布局下,由于不同的工厂、机构以及数据采集节点的拓扑结构非常容易受到外界的干扰。以新能源为主体的新型电力系统中,新能源资源的不确定性、设备的低抗扰和弱支撑性带来了安全挑战,这增加了数据的异质性。此外,由于电力能源部门的数据多涉及敏感信息,涉及到运算的数据/参数交互往往无法在加密的条件下进行,无法做到数据的可用不可见。

在联邦学习(federated learning)中,参与者无需上传隐私敏感数据,模型的训练在参与者的本地进行,训练出本地模型后仅与服务器共享模型的参数、梯度等特征^[14],不交换原始数据,能够非常有效地解决数据分析中的隐私问题^[15]。

为避免人工选择电能质量扰动数据特征的主观性,解决深度学习方法中 CNN 模型所要求的数据量问题,以及实际电能扰动数据的异质性和隐私性问题,文中提出一种使用联邦学习与原型学习(prototype learning)构建的电能质量扰动分类模型,首次将联邦学习和原型学习结合进行电能质量扰动分类。该方法使用多个具有少量本地训练数据的参与方作为不同的训练节点,协同构建 PQD 分类器,多个参与方使用本地的卷积原型网络(convolutional prototype network, CPN)作为特征提取器和本地原型生成器,将生成的本地原型作为服务器聚合的联邦通信主体,服务器聚合后的全局原型包含了不同参与方中同类扰动信号的共性信息。随后参与方利用全局原型作为本地监督学习的加权正则化项,实现个性化的本地分类模型构建。

1 联邦原型学习网络框架

文中所提出的电能质量扰动分类方法中,在联邦学习框架的基础上将原型学习嵌入本地训练。图 1 为所提出用于电能质量扰动分类的联邦原型学习网络框架,不同参与方使用不足以完成独立训练的本地扰动数据和本地 CPN 模型完成单轮训练后,参与方 i 将 CPN 生成的第 j 类扰动信号的本地原型作为联邦学习中协作训练的通信内容,服务器在接收到所有的本地原型后进行平均生成全局原型后,再将其返回给每个参与方,参与方计算本地原型与服务器返回的全局原型作为原型损失 L_r ,将 L_r 作为每一轮监督训练损失 L_s 的加权正则化项,以减少全局的总体训练损失。该全局原型包含了不同参与方中同类扰动数据的分布信息,避免了参与方独立训练时对某一类扰动数据产生的分布偏离,能够有效缓解真实电网设备部署环境下所采集到的数据异质性问题。

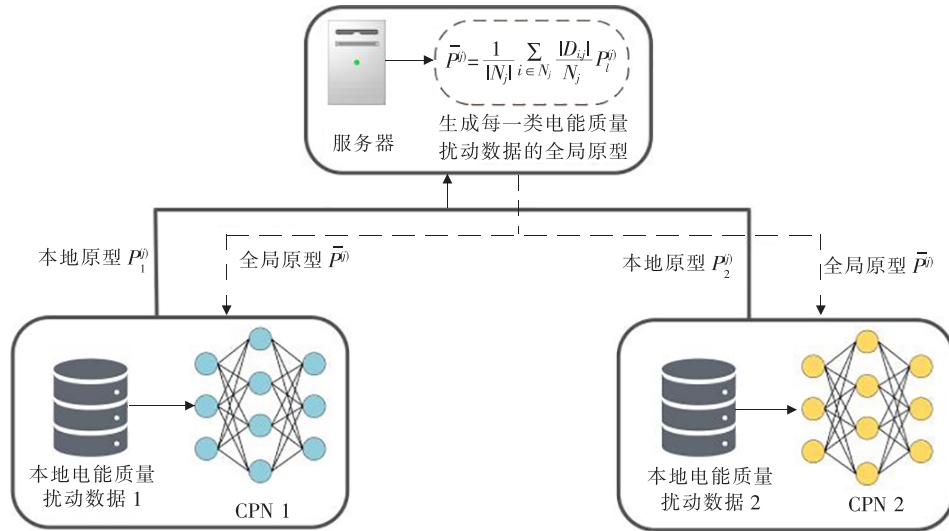


图1 用于电能质量扰动分类的联邦原型框架

Fig.1 Federated prototype framework for power quality disturbance classification

1.1 联邦学习

联邦学习是利用分散在各参与方的数据集,通过隐私保护技术融合多方数据信息,协同构建模型的一种分布式训练方式^[16]。在模型训练过程中,模型的相关信息(如模型参数、模型结构、参数梯度等)能够在各参与方之间进行交换,但本地数据不会离开本地^[17]。

假设当前有 N 个参与方 $\{F_i\}_{i=1}^N$ 共同参与训练,各参与方拥有的本地数据为 $\{D_i\}_{i=1}^N$ 。传统的训练方式要求将所有参与方的本地数据收集起来,在服务器上使用集中后的数据集训练一个全局模型 M_{SUM} 。联邦学习不要求收集各参与方的本地数据便能够协作训练出一个模型 M_{FED} ,假设 V_{SUM} 和 V_{FED} 表示为 M_{SUM} 和 M_{FED} 的性能度量,联邦学习的任务目标为使 V_{FED} 无限逼近或优于 V_{SUM} 。

但在电能质量扰动数据存在异构性的情况下,将导致本地模型参数 ω_i 的形式和大小都不同,对于第 i 个参与方,训练目标旨在将全局损失降至最低,而现有的多数联邦学习框架通过取模型参数 ω_i 的平均值来进行模型优化。此模型优化式表示为:

$$\arg \min_{\omega_1, \omega_2, \dots, \omega_m} \sum_{i=1}^m \frac{|D_i|}{N} L_S(F_i(\omega_i; x), y) \quad (1)$$

式中: x 为训练样本; y 为样本真实值。文章所提出的方法中,本地模型的训练使用交叉熵损失函数作为监督学习的迭代优化项,用公式表示为:

$$L_S = -\frac{1}{N} \sum_{i=1}^m \sum_{k=1}^K y_{i,k} \log(p_{i,k}) \quad (2)$$

式中: m 为样本数量; K 为类别数量; $y_{i,k}$ 和 $p_{i,k}$ 为第 i 个样本的第 k 个标签的真实值和预测值。但这种方式并不能真正缓解多源数据之间的异构性,无法

建立一个适合本地数据分布的个性化模型。

由于原型学习可以不受电能质量扰动数据多视角缺失问题的影响,能够合成包含源域中样本共性的新数据,所以将联邦学习和原型学习相结合,作为缓解多源电能扰动数据之间异构性的方法。

1.2 原型学习

原型学习被称之为核心集构造,也可以视为一种细粒度的聚类方法^[17]。定义源集 X 和目标集 Y ,原型学习从源集 X 中学习到一个原型集 \mathcal{P} ,集合中原型的数量是灵活变化的,该原型集能够最大程度地保持目标集 Y 的内蕴结构,同时原型集中所有元素具有最少的重叠信息。原型集在样本空间中具有充分的覆盖性,从而反映数据的全局特性。

原型同样被用来合成服从目标集分布的新数据,由于深度学习经常面临有效数据不足或缺失问题,该问题在异常检测中至关重要,例如电力盗窃、入侵检测、缺陷识别等。因此将原型学习应用到电能质量扰动分类中,不仅可以净化目标集,还可以合成新的数据,解决数据不足、缺失问题。

原型的获取一般有两种方式,一类是直接从源集中选取代表性的数据来构成原型集,称为选择法;另外一类则是在源集中通过融合方式重新生成一组具有代表性的点,称为生成法。文中方法使用生成法获取每一类电能质量扰动原型,将原型学习和 CNN 结合构建每个参与方的本地模型,称为卷积原型网络。首先使用深层神经网络提取扰动数据的深度特征,之后对特征信息进行融合生成每一类数据的本地原型。对于第 i 个参与方,原型 $P_i^{(j)}$ 是类 j 中样本的嵌入向量 $v_i(\omega_i; x)$ 的平均值,计算式为:

$$P_i^{(j)} = \frac{1}{|D_{i,j}|} \sum_{(x,y) \in D_{i,j}} v_i(\omega_i; x) \quad (3)$$

式中: $D_{i,j}$ 为本地数据集 D_i 的子集, 由属于第 j 类数据实例组成。服务器平均聚合多个参与方的本地原型 $P_i^{(j)}$ 生成第 j 数据的全局原型 $\bar{P}^{(j)}$, 表示式为:

$$\bar{P}^{(j)} = \frac{1}{|N_j|} \sum_{i \in N_j} \frac{|D_{i,j}|}{N_j} P_i^{(j)} \quad (4)$$

式中: N_j 表示拥有 j 类数据的参与方集合, 在服务器将全局原型返回给参与方后, 参与方计算原型损失 L_p , 表示为:

$$L_p = \sum_j d(\bar{P}^{(j)}, P^{(j)}) \quad (5)$$

式中: d 为全局原型和本地原型之间的距离度量; 度量方式为均方误差损失; $P^{(j)}$ 表示为第 j 类的本地原型; $\bar{P}^{(j)}$ 为服务器返回的第 j 类全局原型; L_p 将作为监督学习 L_s 的正则化项。

1.3 卷积原型网络

文中所提出的方法中, 所有参与方构建的本地卷积原型网络结构如图 2 所示。

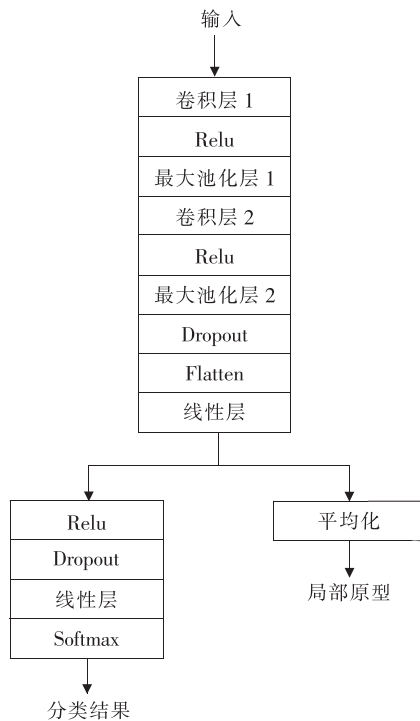


图 2 每个参与方的本地卷积原型网络结构
Fig. 2 Local convolutional prototype network structure for each client

首先, 扰动数据经过卷积层 1 完成对输入信息的特征提取, 得到局部信息, 卷积层的卷积核大小为 5, 卷积步长设置为 1; 之后对局部信息使用 Relu 激活函数进行非线性变换; 其次, 非线性变换的输出输入到最大池化层 1, 通过减少采样操作次数来

降低特征的数量, 减少参数量, 防止过拟合, 最大池化层的卷积核大小为 2。再次重复上述操作之后, 最大池化层 2 的输出经过 Dropout 层, 使部分神经元的激活值以一定的概率停止工作, 可以使模型泛化性更强, 之后使 Flatten 层将 Dropout 层的输出“压平”, 即把多维的特征值一维化。

输入的电能扰动数据经过 CNN 网络进行深度特征提取后, 经过线性层之后被分为两个支路。第一条支路作为监督学习的分类输出结构, 通过 Softmax 函数得到最终扰动类别标签。第二条支路对低维展开后的深层特征信息进行平均得到本地原型, 该本地原型作为全局通信的信息主体, 包含了每类数据的内蕴信息。

1.4 隐私保护策略

原型是同类样本经过卷积网络提取之后, 全连接层所输出特征向量的平均值, 表示为一维的特征向量, 且文中的假设为恶意攻击者无法访问参与方的本地数据以及本地训练模型。

首先, 样本重构的角度进行分析, 在攻击者已知特征向量和本地模型具体结构的情况下, 也无法精确地从全连接层输出的特征向量直接反向重构出模型的输入数据。这是因为全连接层输出的特征向量已经经过了多次非线性变换, 其中的信息已经被混合和压缩, 无法直接还原出原始的输入数据。

其次, 在未知本地模型具体结构的前提下, 仅从卷积神经网络中全连接层输出的特征向量反向重构出模型的输入数据将更加困难。这是因为本地模型中的细节和结构已经对输入数据的特征表示产生了影响, 而这些信息无法简单地从特征向量中推断出来。特别的, 如果本地模型的训练过程中使用了特殊的损失函数或正则化方法, 那么重构出原始数据的可能性将变得更低, 而文中以原型损失作为交叉熵损失正则项的方法将再次降低反向重构的可能性。

最后, 以上两种情况均是在单个训练样本对应其特征向量情况下的反向重构分析, 而文中的本地原型是某一类扰动信号所有特征向量的平均值, 原型是高级统计信息, 其本身不属于任何一个原始样本对应的特征向量, 因此, 攻击者在不知道本地模型具体结构, 仅从通信过程中获取本地原型重构出特定的一个输入样本数据将是不可能的。

1.5 通信效率

联邦学习的学习过程总体包含本地计算和通信传输两大环节, 因此, 降低通信开销主要围绕这两个环节进行。第一个策略是增加本地计算量与通信间隔、减少通信频次。受参与方的网络带宽和跨地域地影响, 为了尽可能地减少参与方与服务器之间的通信次数, 避免造成不必要的通信开销。第

二个策略是减少通信内容。随着卷积神经网络层数的加深,模型所具有的参数量将极大增加,以 ResNet50^[18] 网络模型为例,具有大于 6 000 万个参

数。若将如此多的浮点数值发送给服务器将产生巨大的通信开销,并且这样的通信开销会随着参与方数据量和迭代轮次的增加而增加,如表 1 所示。

表 1 正常信号和扰动信息的数学模型及参数设置

Tab. 1 Mathematical model and parameter settings for normal signal and disturbance information

信号类型	数学模型	参数
C0	$A \sin(\omega t)$	$A = 1, \omega = 50\text{Hz}$
C1	$A \{1 + \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$0.1 \leq \alpha < 0.8, T \leq t_2 - t_1 \leq 9T$
C2	$A(\sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) + \alpha_{11} \sin(11\omega t))$	$\alpha_3 = \alpha_5 = \alpha_7 = \alpha_{11} = 0.05 \sim 0.15$
C3	$A[1 + \alpha \sin(\beta \omega t)] \sin(\omega t)$	$0.1 \leq \alpha \leq 0.2, 0.1 \leq \beta \leq 0.2$
C4	$A \{1 - \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$0.9 \leq \alpha \leq 1.0, T \leq t_2 - t_1 \leq 8T$
C5	$A \{1 - \alpha [u(t - t_1) - u(t - t_2)]\} \sin(\omega t)$	$0.1 \leq \alpha < 0.9, T < t_2 - t_1 < 8T$
C6	$A[1 - (u(t - t_1) - u(t - t_2))] \sin(\omega t)$	$T/20 \leq t_2 - t_1 \leq T/10$
C7	$\alpha e^{-c(t-t_1)} \times [u(t - t_1) - u(t - t_2)] \sin(\beta \omega t) + \sin \omega t$	$0.1 \leq \alpha \leq 0.8, T < t_2 - t_1 < 3T$

2 仿真实验结果与分析

2.1 仿真实验数据集

根据 PQD 信号的数学模型,以及 IEEE Std. 1159 电能质量标准^[19-20],使用 MATLAB 2018 分别为 5 个参与方分别生成 2 000 个本地样本,包含正常信号(C0)和瞬升(C1)、谐波(C2)、闪变(C3)、中断(C4)、瞬降(C5)、脉冲暂态(C6)和振荡暂态(C7)7 类常见的电能质量扰动信号,如表 1 所示。幅值 A 设为 1,采样周期 T 为 0.02 s,基波频率为 50 Hz,采样频率 f 为 3 915 Hz,采样区间是 10 个周期,也就是 0.2 s 采样 783 次,一共 784 个采样点。 α 为附加扰动幅值, t_1 和 t_2 分别为扰动开始时间和结束时间。扰动信号的 MATLAB 仿真波形如图 3 所示。每个参与方本地的训练数据和测试数据划分比例为 7:3,随机选取其中 1 400 个作为训练样本,600 个作为测试样本。

2.2 仿真实验参数设计

在仿真实验参数设计中,全局更新迭代 120 次,在每一轮全局更新迭代中,本地 CPN 模型更新迭代 10 次。参与方个数设置为 5,这个 5 个参与方的本地原型全部参与聚合。模型输入的最小批尺寸为 128,使用随机梯度下降优化器,动量设置为 0.5,学习率为 0.01。原型损失的正则化权重 λ 为 1。

2.3 仿真实验环境

电能质量扰动分类的仿真实验使用 Python 语言编程,基于 Pycharm 编译器和 Pytorch 深度学习框架,使用 GPU 进行模型训练,显卡型号为 NVIDIA GeForce GTX 1650 Ti。

2.4 评价指标

文中使用准确率(Accuracy)作为仿真实验结果的评价指标,通过混淆矩阵计算,如表 2 所示。

TP 为预测值和真实值都是 1 的数, TN 为预测值和真实值都是 0 的数。 FP 为真实值为 0 预测值为 1 的数, FN 为真实值为 1 和预测值为 0 的数。 $Accuracy$ 公式如下:




图 3 电能质量扰动信号仿真波形

Fig. 3 PQD signal simulation waveform

表 2 混淆矩阵
Tab. 2 Confusion matrix

		真实值	
		Positive	Negative
预测值	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

2.5 模型的实现与训练过程分析

为了比较不同数量参与方的 CPN 模型在训练过程中的具体表现,将每个模型的训练准确率、训练损失关于训练轮数的收敛趋势进行统计,如图 4 ~ 图 8 所示。




图 4 参与方 1 的训练准确率和训练损失
Fig. 4 Training accuracy and loss for client 1




图 5 参与方 2 的训练准确率和训练损失
Fig. 5 Training accuracy and loss for client 2




图 6 参与方 3 的训练准确率和训练损失
Fig. 6 Training accuracy and loss for client 3




图 7 参与方 4 的训练准确率和训练损失
Fig. 7 Training accuracy and loss for client 4




图 8 参与方 5 的训练准确率和训练损失
Fig. 8 Training accuracy and loss for client 5

可以看到每个模型关于训练准确率的收敛曲线随着训练轮数的增加成较好的递增趋势,在达到 120 轮时已经完全收敛。同样,5 个模型关于训练损失的收敛曲线随着训练轮数的增加,总体呈递减趋势,当达到 120 轮时已经基本收敛。两种曲线的趋势说明 CPN 网络模型有着良好的训练性能,即随着训练轮数的增加,文中所提出的电能扰动分类方法针对不同参与方之间的异构扰动数据,CPN 模型性能已经逐步完善,说明原型学习与 CNN 结合的训练方式,能够避免传统单一 CNN 模型容易受异构偏移值影响的问题,对异构数据具有较高的鲁棒性。

图 9 为参与方 4 本地模型的测试结果,将输出的测试结果制作成混淆矩阵,用来直观体现模型对每一类信号的分类结果。由图 9 可以观察到 8 类信号中有 7 类信号均预测正确,只有一类扰动信号没有全部分类正确。

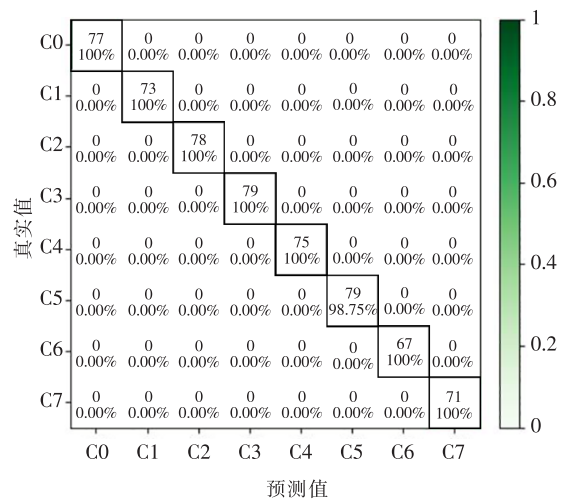


图 9 参与方 4 的混淆矩阵
Fig. 9 Confusion matrix of client 4

这是因为使用原型作为多个参与方之间协同构建模型的信息媒介时,不易受到单一类别数据产生的偏离影响,但能有效地提取各种类型的扰动数据,特别是对多源异构数据具有较强的泛化性。

由于不同参与方在协同训练本地模型时需要向服务器传输本地原型进行聚合,当存在本地数据质量不好或对全局模型更新优化起负面作用的参与方,将使其他参与方的模型产生偏离,这对全局更新是非常不利的。因此,在每一轮全局更新时随机选取本地原型参与服务器端的本地聚合,以验证不同的本地原型个数对模型产生的影响,随机选取 2、3、4 个本地原型以及全部本地原型均参与聚合后的仿真实验结果如表 3 所示。上述方法的理论是基于第 1 节所提出的电能质量分类方法,该实验的目的是寻找所提出方法关于最佳原型聚合数目的超参数,进而在此参数设置下与其他方法进行对比。仿真实验结果以第 2.4 节所描述的 Accuracy 为指标,均为完成 10 次验证之后取其平均值。该实验结果均是在第 2.3 节所表述的实验环境下获得,使用 Pycharm 与 Matlab 作为编程软件,均在 GPU 显卡上进行实验。

表 3 随机参与方选择实验结果

Tab. 3 Experimental results of random client selection

参与方	本地原型随机聚合数目			
	2	3	4	5
参与方 1	0.976 7	0.980 0	0.105 0	0.955 0
参与方 2	0.125 0	0.438 3	0.988 3	0.983 3
参与方 3	0.988 3	0.991 7	0.990 0	0.981 7
参与方 4	0.988 3	0.990 0	0.990 0	0.993 3
参与方 5	0.976 7	0.911 7	0.976 7	0.968 3

仿真实验结果表明,当所有的本地原型参与聚合所生成的全局原型能够将包含更多的同类扰动信号的空间分布信息,这对所有参与方的本地模型优化更为有利,因此将所有的本地原型均上传至服务器进行聚合,以完成全局的迭代更新。

2.6 对比实验

为了进一步验证文中所提出的电能质量扰动分类方法的优势,将文中方法与基于双层 SVM 的电能质量扰动信号分类方法^[21]、基于 CNN 的电能质量扰动分类算法^[22]以及使用 FedAvg^[23]框架构建的联邦学习分类方法进行了对比,实验结果如表 4 所示,表 4 与表 3 均在同样的条件下进行仿真实验。

由表 4 可知,使用 CNN 构建分类网络的方法优于 SVM,这是因为 CNN 能够提取扰动信号数据中的更深层信息,具有较好的分类准确率;而使用 FedAvg 构建的联邦平均算法,虽然本地模型使用的是同样的 CNN 网络,但由于只是对模型参数进行加权平均,对于多源异构扰动信号的鲁棒性较差;而文中所提方法在联邦学习框架下,将 CNN 和原型学习相结合,构建的 CPN 网络在拥有 CNN 强大特征提

取能力的同时,使用原型作为联邦学习协同更新本地模型时的通信内容。仿真实验结果说明了文中所提方法,通过使用多个参与方的本地数据协同构建的分类模型,全局原型集合中的每一个原型都能最大程度地蕴含同类扰动数据的共性信息,这对多源异构数据具有鲁棒性和适应性,能够对多种电能质量扰动信号实现较高的分类准确率,因此文中所提出方法的分类性能优于其他方法。

表 4 与其他方法进行对比

Tab. 4 Comparison with other methods

参与方	方法			
	SVM	CNN	FedAvg	文中方法
参与方 1	0.953 3	0.966 1	0.948 9	0.986 2
参与方 2	0.959 7	0.979 4	0.944 9	0.991 7
参与方 3	0.956 2	0.970 9	0.949 9	0.988 3
参与方 4	0.958 3	0.968 9	0.940 9	0.998 3
参与方 5	0.956 0	0.969 9	0.951 9	0.982 8

2.7 本地计算量与通信参数量

在本地计算环节中,通过增加参与方本地的计算量,进而减少参与方与服务器之间的数据传输频次,最终达到降低参与方与服务器之间的通信开销。

在仿真实验中,本地模型训练轮次由原来的 1 轮增加到 4 轮之后再上传本地原型。本中所提方法建立的本地模型参数量有 89 740 个,如表 5 所示,将 FedAvg 方法的本地模型设置为与文中方法相同的网络结构。

表 5 通信传输的参数对比

Tab. 5 Comparison of communication transmission parameters

方法	参数量/个	传输数据量/M
FedAvg	89 740	0.342 3
文中方法	1 024	0.003 9

参数所占内存为 0.342 3 M,如果将其作为通信传输内容,通信开销将是巨大的。相较于多数联邦学习方法中将网络模型参数作为通信主体,使用具有更少参数量的原型作为通信内容,每一类原型为平均之后的特征向量,具有 128 个参数,因此 8 类信号的本地原型总共包含 1 024 个参数,这将极大减少数据传输内容,从而减低传输开销。

3 结束语

为提高新型电网环境下异构电能质量扰动信号的识别准确率和隐私信息保护,文中提出将联邦学习和原型学习相结合的方法,用于异构电能质量扰动信号的识别。由于所构建的 CPN 模型不同与传统 CNN 模型,无需大量的训练数据,且对多源异

构数据不敏感,因此具有较强的鲁棒性。利用 CPN 模型自动提取电能质量扰动信号的特征,不仅解决了人工提取特征值时存在的误差问题,将其作为参与方之间的通信主体时无法被推断攻击获取隐私信息,这一特性是其他方法不具备的。从实验结果来看,文中所提出方法的分类准确率最高能达 0.998 3,相比于其他方法具有较大优势,在新型电力系统下的电能质量扰动分类领域具有较大的应用前景。

未来的研究方向将进一步验证隐私保护级别,在参与方与服务器之间的通信效率方面进一步加以优化,同时将围绕复合场景下的电能质量扰动展开研究。

参 考 文 献

- [1] 黄雨涵,丁涛,李雨婷,等. 碳中和背景下能源低碳化技术综述及对新型电力系统发展的启示[J]. 中国电机工程学报, 2021, 41(S1): 28-51.
HUANG Yuhuan, DING Tao, LI Yuting, et al. Decarbonization technologies and inspirations for the development of novel power systems in the context of carbon neutrality [J]. Proceedings of the CSEE, 2021, 41(S1): 28-51.
- [2] 王康,席燕辉,胡康. 一种新的基于深度置信网络的电能质量扰动分类方法[J]. 电力科学与技术学报, 2023, 38(1): 171-177.
WANG Kang, XI Yanhui, HU Kang. A novel classification method for power quality disturbance based on deep belief network [J]. Journal of Electric Power Science and Technology, 2023, 38(1): 171-177.
- [3] 王金浩,刘愈倬,薛磊,等. 基于 dq 变换、小波变换及 FFT 的电能质量扰动识别[J]. 现代电力, 2010, 27(3): 16-20.
WANG Jinhao, LIU Yuzhuo, XUE Lei, et al. Power quality disturbance identification based on dq conversion, wavelet transform and FFT [J]. Modern Electric Power, 2010, 27(3): 16-20.
- [4] 徐长宝,古庭赟,高云鹏,等. 基于改进小波阈值函数和变分模态分解的电能质量扰动检测[J]. 湖南大学学报(自然科学版), 2020, 47(6): 77-86.
XU Changbao, GU Tingyun, GAO Yunpeng, et al. Power quality disturbance detection based on improved wavelet threshold function and variational mode decomposition [J]. Journal of Hunan University (Natural Sciences), 2020, 47(6): 77-86.
- [5] 布左拉·达吾提,帕孜来·马合木提,董永昌,等. 一种改进 EMD-SVD 算法的暂态电能质量扰动信号消噪研究[J]. 电测与仪表, 2021, 58(12): 69-75.
BUZUOLA · DAWUTI, PAZILAI · MAHEMUTI, DONG Yongchang, et al. Research for denoising of transient power quality disturbance signal based on improved EMD-SVD algorithm [J]. Electrical Measurement & Instrumentation, 2021, 58(12): 69-75.
- [6] 奚鑫泽,邢超,覃日升,等. 基于多层特征融合注意力网络的电能质量扰动识别方法[J]. 智慧电力, 2022, 50(10): 37-44.
XI Xinzhe, XING Chao, QIN Risheng, et al. Power quality disturbance recognition method based on multi-layer feature fusion attention network [J]. Smart Power, 2022, 50(10): 37-44.
- [7] 张喆,孟祥亮,肖新华,等. 配电网电能质量复合扰动检测研究[J]. 电网与清洁能源, 2023, 39(2): 40-45.
ZHANG Zhe, MENG Xiangliang, XIAO Xinhua, et al. Research on power quality composite disturbance detection in power distribution IOT [J]. Power System and Clean Energy, 2023, 39(2): 40-45.
- [8] 陈晓华,王志平,吴杰康,等. 基于 IHHO-SVM 的电能质量扰动信号识别方法[J]. 浙江电力, 2023, 42(8): 115-124.
CHEN Xiaohua, WANG Zhiping, WU Jiekang, et al. Identification method for disturbance signal of power quality based on improve Harris Hawks optimization-support vector machine [J]. Zhejiang Electric Power, 2023, 42(8): 115-124.
- [9] 吴怀诚,刘家强,岳蕾,等. 基于多特征融合的卷积神经网络的电能质量扰动识别方法[J]. 电网与清洁能源, 2023, 39(9): 19-23, 31.
WU Huaicheng, LIU Jiaqiang, YUE Lei, et al. Identification of power quality disturbances based on MFCNN [J]. Power System and Clean Energy, 2023, 39(9): 19-23, 31.
- [10] 王凯,孙贤明,任成昊,等. 基于多尺度融合选择卷积网络的电能质量扰动识别[J]. 现代电子技术, 2022, 45(4): 107-112.
WANG Kai, SUN Xianming, REN Chenghao, et al. Power quality disturbance recognition based on multi-scale fusion selection convolutional network [J]. Modern Electronics Technique, 2022, 45(4): 107-112.
- [11] 董光德,李道明,陈咏涛,等. 基于粒子群优化与卷积神经网络的电能质量扰动分类方法[J]. 发电技术, 2023, 44(1): 136-142.
DONG Guangde, LI Daoming, CHEN Yongtao, et al. Power quality disturbance classification method based on particle swarm optimization and convolutional neural network [J]. Power Generation Technology, 2023, 44(1): 136-142.
- [12] LI J S, LIU H, WANG D K, et al. Classification of power quality disturbance based on S-transform and convolution neural network [J]. Frontiers in Energy Research, 2021, 9: 708131-708131.
- [13] 罗溢,李开成,肖贤贵,等. 基于马尔可夫转移场和深度残差网络的电能质量复合扰动多标签分类[J]. 中国电机工程学报, 2023, 43(3): 1-11.
LUO Yi, LI Kaicheng, XIAO Xiangui, et al. Multi-label

- classification of power quality composite disturbances based on markov transfer field and Resnet[J]. Proceedings of the CSEE, 2023, 43(3): 1-11.
- [14] WANG Lingling, ZHAO Xueqin, LU Zhongkai, et al. Enhancing privacy preservation and trustworthiness for decentralized federated learning[J]. Information Sciences, 2023, 628: 449-468.
- [15] ZHAI R, CHEN X B, PEI L T, et al. A federated learning framework against data poisoning attacks on the basis of the genetic algorithm[J]. Electronics, 2023, 12(3): 560-560.
- [16] CAMPOLO C, GENOVESE G, SINGH G, et al. Scalable and interoperable edge-based federated learning in IoT contexts[J]. Computer Networks, 2023, 223: 109576.
- [17] 张幸幸, 朱振峰, 赵亚威, 等. 机器学习中原型学习研究进展[J]. 软件学报, 2022, 33(10): 3732-3753.
ZHANG Xingxing, ZHU Zhenfeng, ZHAO Yawei, et al. Prototype learning in machine learning: A literature review [J]. Journal of Software, 2022, 33(10): 3732-3753.
- [18] 辜瑞帆, 李祥, 任维民. 基于 ResNet50 改进模型的图像分类研究[J]. 现代电子技术, 2023, 46(4): 107-112.
GU Ruifan, LI Xiang, REN Weimin. Research on image classification based on ResNet50 improved model[J]. Modern Electronics Technique, 2023, 46(4): 107-112.
- [19] 张锐, 张闯, 高辉, 等. 基于自适应特征增强分组卷积网络的电能质量扰动分类[J]. 中国电机工程学报, 2023, 43(15): 5808-5817.
ZHANG Rui, ZHANG Chuang, GAO Hui, et al. Power quality disturbances classification based on grouping convolutional network with adaptive feature enhanced network [J]. Proceedings of the CSEE, 2023, 43(15): 5808-5817.
- [20] 黄公跃, 付婷婷, 林思远, 等. 用电信息采集系统电能计量数据异常识别研究[J]. 电网与清洁能源, 2023, 39(4): 25-30, 46.
HUANG Gongyue, FU Tingting, LIN Siyuan, et al. A study on abnormal identification of electric energy measurement data in electric energy information acquisition system [J]. Power System and Clean Energy, 2023, 39(4): 25-30, 46.
- [21] 李琦, 许素安, 施阁, 等. 基于 S 变换和 IWOA-SVM 的复合电能质量扰动识别[J]. 智慧电力, 2023, 51(5): 30-35, 50.
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35, 50.
- [22] 瞿合祚, 李晓明, 陈陈, 等. 基于卷积神经网络的电能质量扰动分类[J]. 武汉大学学报(工学版), 2018, 51(6): 534-539.
QU Hezuo, LI Xiaoming, CHEN Chen, et al. Classification of power quality disturbances using convolutional neural network[J]. Engineering Journal of Wuhan University, 2018, 51(6): 534-539.
- [23] 周威振, 马越, 邓集瀚, 等. 基于 FedAVG-SA-BP 的变压器 DGA 故障诊断[J]. 变压器, 2023, 60(9): 31-35.
ZHOU Weizhen, MA Yue, DENG Jihan, et al. Transformer DGA fault diagnosis based on FedAVG-SA-BP[J]. Transformer, 2023, 60(9): 31-35.

作者简介:



李琮琮(1985—),女,通信作者,硕士,研究方向为用电信息采集。
Email:coco_0209@163.com

王清(1984—),男,博士,研究方向为用电信息采集。
Email:1799726266@qq.com

荆臻(1981—),男,硕士,教授,研究方向为电能计量。
Email:32194587@qq.com

收稿日期:2023-09-27;修回日期:2024-04-12
(杜景飞 编发)