

doi:10.3969/j.issn.1673-9833.2025.03.005

# 基于联邦学习的非侵入式电力负荷分解

唐雄峰<sup>1, 2</sup>, 王俊年<sup>1, 2</sup>, 唐佳林<sup>1, 2</sup>

(1. 湖南科技大学 物理与电子科学学院, 湖南 湘潭 411201;  
2. 智能传感器与新型传感材料湖南省重点实验室, 湖南 湘潭 411201)

**摘要:** 针对传统的电力负荷分解时用户上传用户数据可能存在的隐私泄露问题, 提出利用条件生成对抗网络(cGAN)模型, 通过联邦学习的方式, 进行电力负荷模型训练的方案。利用本地每个用户少量的数据集对模型进行训练, 用户上传训练后模型的相关参数到服务端, 服务端将收集到的参数进行整理和聚合后, 将模型参数下放给用户。确保本地用户数据没有外泄的情况下, 对模型进行了训练。利用公开数据集UK\_DALE, 实验验证了该方法的有效性。

**关键词:** 非侵入式电力负荷监测; 数据外泄; 隐私保护; 联邦学习; cGAN 网络

**中图分类号:** TM714 **文献标志码:** A **文章编号:** 1673-9833(2025)03-0031-08

**引文格式:** 唐雄峰, 王俊年, 唐佳林. 基于联邦学习的非侵入式电力负荷分解[J]. 湖南工业大学学报, 2025, 39(3): 31-38.

## Non-Invasive Power Load Decomposition Based on Federated Learning

TANG Xiongfeng<sup>1, 2</sup>, WANG Junnian<sup>1, 2</sup>, TANG Jialin<sup>1, 2</sup>

(1. College of Physics and Electronic Science, Hunan University of Science and Technology, Xiangtan Hunan 411201, China;  
2. Hunan Provincial Key Laboratory of Intelligent Sensors and New Sensing Materials, Xiangtan Hunan 411201, China)

**Abstract:** In view of the flaw of privacy leakage problem in the process of uploading user data by users during traditional power load decomposition, a scheme has thus been proposed to train the power load model through federated learning by using the Conditional Generative Adversarial Network (cGAN) model. By using a small amount of data set from each local user model training, users upload the relevant parameters of the trained model to the server, which subsequently organizes and aggregates the collected parameters, with the model parameters further distributed to the users. It is guaranteed that local user data remains private while still enabling model training, with the effectiveness of this method validated through experiments on the publicly available UK\_DALE dataset.

**Keywords:** non-intrusive power load monitoring; data leakage; privacy protection; federated learning; cGAN network

## 0 引言

随着居民生活水平的不断提高, 家庭使用电器的种类越来越多, 家庭电力能源消耗也不断攀升, 根

据美国能源消耗统计数据, 70%的电力资源消耗来自室内。随着能源危机加剧和人们环保意识的增强, 需要更加精细化的电力能源管理<sup>[1]</sup>。无论是供给侧电

收稿日期: 2024-03-12

作者简介: 唐雄峰, 男, 湖南科技大学硕士生, 主要研究方向为非侵入式电力负荷分解,

E-mail: 21020802019@mail.hnust.edu.cn

通信作者: 王俊年, 男, 湖南科技大学教授, 博士生导师, 主要研究方向为智能信息处理, 复杂系统建模及故障诊断, 密码设备侧信道分析等研究, E-mail: jnwang@hnust.cn

力能源管理还是需求侧家庭电力能源管理,都需要了解家庭中每个电器的用电情况<sup>[2]</sup>。

目前电力公司或家庭想了解家庭各用电设备的用电情况,主要通过侵入式电力负荷监测(intrusive load monitoring, ILM)和非侵入式电力负荷监测(non-intrusive load monitoring, NILM)两种方法。ILM方法通过对各个电器布置传感器硬件获取电器的使用情况,而NILM方法则将工作重点由硬件收集电器功率信息转移到由算法估计功率信息,通过家庭入户电表提供的总信号信息,利用NILM算法估算每个电器的电能消耗<sup>[3]</sup>。

侵入式电力负荷监测可以精准地了解家庭中每个用电设备的用电情况,该方式虽然不需要模型训练,直接通过传感器获取每个用电设备的使用情况,但是该方式需要大量的人力和物力<sup>[4]</sup>。相比于侵入式电力负荷监测,非侵入式电力负荷监测通过对总功率进行采集后,利用机器学习模型进行电力分解,因此也称为非侵入式电力负荷分解。非侵入式电力负荷分解可以通过分解总功率,较为准确地获取家庭中每个用电设备的用电情况<sup>[5]</sup>。该方式虽然减少了大量的人力物力消耗,但是非侵入式电力负荷分解的模型训练,需要用户上传大量的各电器用电数据进行NILM算法模型训练,在进行NILM算法模型训练的同时也伴随客户隐私外泄。

传统集中式模型训练方法会增加服务端计算和通信压力,并且无法保护用户的数据隐私。因此,本文提出通过利用联邦学习的方式进行非侵入电力负荷分解,在确保用户隐私的情况下,降低服务器对集中式数据集的依赖,进行机器学习模型训练,并在公开数据集UK\_DALE上得到了验证。

## 1 电力负荷分解模型

### 1.1 非侵入式网络选择

由于目前市面上大部分非侵入式电力负荷分解模型的分解效果并不理想,其分解效果很难满足用户需求,且传统集中式模型训练需要同时输入大量数据,极大地增加了数据通讯压力,而在采用联邦式电力负荷分解时,仅需用用户本地少量的数据集就能达到较好的模型训练效果。为了解决当前模型在分解效果上的不足,课题组利用一种基于生成对抗网络(generative adversarial networks, GAN)方法,旨在通过引入GAN的生成器和判别器来改善非侵入式电力负荷分解的精确度和准确性。具体来说,采用了条件生成对抗网络(cGAN)网络结构,将其应用于联邦式电力负荷分解任务中。本研究中,将探讨如何在

联邦学习框架下,利用少量的数据集来训练改进的cGAN模型,从而实现更准确的电力负荷分解。

### 1.2 cGAN网络的非侵入式电力负荷分解

与传统的GAN网络相比,cGAN网络通过引入标签,使生成的数据更加可控,同时也将GAN网络架构由无监督学习转为监督学习,诱导模型生成所需数据<sup>[6]</sup>。电力负荷分解的cGAN模型如图1所示。

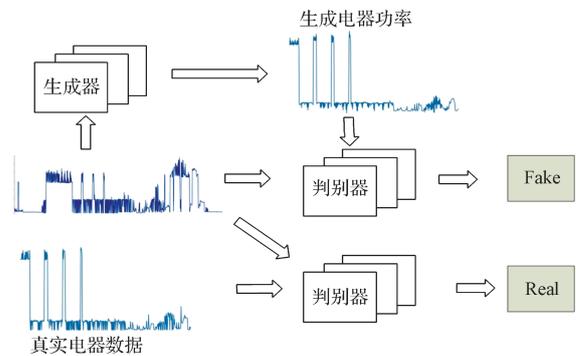


图1 条件对抗网络的负荷分解模型

Fig. 1 Load decomposition model of conditional adversarial networks

cGAN和传统生成对抗网络的架构相似,都有生成器和判别器,将电器总功率输入生成器中,生成网络通过学习电器的功率特征,分解出相应电器的功率序列,利用判别器判别生成器生成的电器功率是否真实<sup>[7]</sup>。cGAN网络的判别器与传统GAN网络不同,传统GAN网络中没有其他的条件约束,只通过引入噪声,利用噪声生成所需要的数据,导致生成器生成的数据不可控,且会增加模型的训练时长,浪费电脑的计算资源<sup>[8]</sup>。而cGAN网络通过在生成器和判别器当中分别引入了标签,利用标签约束生成器的数据生成,使生成器的生成数据更符合需要。通过不断地迭代训练生成器和判别器,判别网络与生成网络不断对抗,相互学习,最终模型能够生成足够真实的数据满足实验要求。

### 1.3 cGAN网络的基础架构

由于电器总功率作为一维数组序列进入模型,模型的输出也是一维数据,模型输入与输出之间的每个数据又相关联,此类模型类似于语言翻译,因此在生成器网络选择采用的是编码器和解码器(encoder-decoder)结构,来实现两者之间的映射关系<sup>[9]</sup>。课题组采用的cGAN网络中生成网络采用U-net网络结构,因为U-net网络是传统的编码器和解码器(encoder-decoder)结构,结构简单且效果较好,被应用于多个领域<sup>[10]</sup>。

本文中的判别网络架构主要由几层卷积层网络组成。由于电器功率的判别主要通过电器的功率特

征提取进行, 因此判别器的网络由全卷积网络构成, 由网络进行数据特征的提取、判别, 如表 1 所示。

表 1 判别网络的网络层

Table 1 Distinguishing the network layer of a network

Layer	Discriminator Network
Layer_1	Conv2d, Filters=64, stride=(2, 1), activation = ReLU
Layer_2	Conv2d, Filters=64*2, stride=(2, 1), BatchNorm, activation= ReLU
Layer_3	Conv2d, Filters=64*4, stride=(2, 1), BatchNorm, activation= ReLU
Layer_4	Conv2d, Filters=64*4, stride=(1, 1), BatchNorm, activation= ReLU
Layer_5	Conv2d, Filters=1, stride=(1, 1), activation=sigmoid

#### 1.4 损失函数

在本实验中, 采用联邦学习方法处理重要数据传输问题。联邦学习允许多个参与者在共享原始数据的情况下进行模型训练, 但在训练中需要传输模型参数。为了最小化数据传输开销和减少隐私泄露风险, 引入了参数稀疏化技术。这一技术能够只传输模型中关键参数的信息, 而忽略对模型性能贡献较小的参数。通过这种方式, 能够有效减少数据传输量, 同时保持模型性能。考虑模型相似性以及模型各个节点的数据量, 本文采用参数稀疏化方式对模型的损失函数进行改进。

实验中, 采用 cGAN 网络模型训练数据的基本模型, 相比传统的 GAN 网络模型, cGAN 网络模型引入了标签, 所以网络中对应的损失函数也发生了相应变化, 传统的 GAN 网络的损失函数如式 (1) 所示:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data(x)}} [\log_2 D(x)] + E_{z \sim P_{(z)}} [\log_2 (1 - D(G(z)))] \quad (1)$$

式中:  $E$  为期望值;  $x$  为真实样本数据;  $y$  为条件信息;  $z$  为引入的随机噪声;  $D$  为判别器;  $G$  为生成器;  $P_{data(x)}$  为采样数据点  $x$  的概率分布;  $P_{(z)}$  为随机噪声的向量分布;  $D(x)$  为判别器对真实数据的判别结果;  $G(z)$  为生成器预测的数据;  $D(G(z))$  为判别器对于预测数据的判别结果。

但是由于 cGAN 网络中, 在模型的判别器和生成器中都引入了额外的信息  $y$ , 因此需要对判别器和生成器的  $x$  与  $z$  进行合并, 因此 cGAN 网络的损失函数如式 (2) 所示:

$$\min_G \max_D V(D, G) = E_{x \sim P_{data(x)}} [\log_2 D(x|y)] + E_{z \sim P_{(z)}} [\log_2 (1 - D(G(z|y)))] \quad (2)$$

在传统的损失函数中, 通过引入  $L_1$  损失函数对模型进行参数稀疏化。 $L_1$  正则化通常用于解决高维数据集上的特征选择和模型简化问题。在联邦学习中,  $L_1$  正则化可以用于减小每个参与者的模型参数量, 从而降低通信开销和隐私泄露风险。在  $L_1$  正则化中, 模型的部分参数会趋向于 0, 从而实现模型参数稀疏化, 让模型更加容易解释和贮存, 同时减少模型的通信压力。 $L_1$  正则化损失函数如式 (3) 所示:

$$L_1(loss(x, y)) = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)| \quad (3)$$

式中:  $y_i$  为真实值;  $f(x_i)$  为预测值。

将  $L_1$  损失函数引入生成器中, 如式 (4) 所示:

$$L_1(G) = E_{x,y,z} [\|y - G(x, z)\|_1] \quad (4)$$

因此网络的整体损失函数公式为

$$\min_G \max_D V_{L_1}(D, G) = V(D, G) + \lambda E_{z \sim P_{(z)}, y \sim P_{data(y)}} [\|y - G(z|x)\|_1] \quad (5)$$

式中  $\lambda$  为人为的引入权重。

#### 1.5 联邦学习与 cGAN 网络结合

相比于传统的集中式机器学习, 联邦学习更加注重对客户隐私的保护, 集中式模型训练需要巨大的计算量, 并且由于不同用户的数据通常是非独立同分布的, 这使得统一模型不能深入挖掘某一特定用户的数据特征。因此课题组通过联邦学习与传统网络相结合的新型模型训练方式, 通过多个地点的网络训练后, 进行模型汇总, 构建更好的网络。

联邦学习一般分为横向联邦和纵向联邦, 横向联邦是指多个用户拥有相同的特征空间, 如都有相同或相似的数据和标签, 相当于每个用户都可以相当于一个小规模数据集<sup>[11]</sup>。而纵向联邦学习的本质是特征联合, 适用于拥有相同的用户, 但是共享特征较少的情况<sup>[12]</sup>。在现实生活中, 每个家庭的电器功率和总功率是独有的, 不同客户之间并没有关联, 所以非侵入式的电力负荷分解采用横向联邦学习。横向联邦学习的主要步骤如下: 客户端从服务端下载最新模型, 客户端利用自己本地的数据集进行模型训练。将训练后的模型参数加密上传给服务端, 服务端将收到的模型参数进行聚合, 更新模型参数, 然后下放给客户端, 不断重复该过程, 如图 2 所示。

本文的横向联邦学习方式采用平均联邦学习 (FedAvg) 方式, 平均联邦将收集到的客户端的模型参数进行加权取平均, 得到新的模型参数, 再将新的参数赋值到模型中, 在不断地更新交替中, 模型最终趋于一个平衡状态<sup>[13]</sup>。

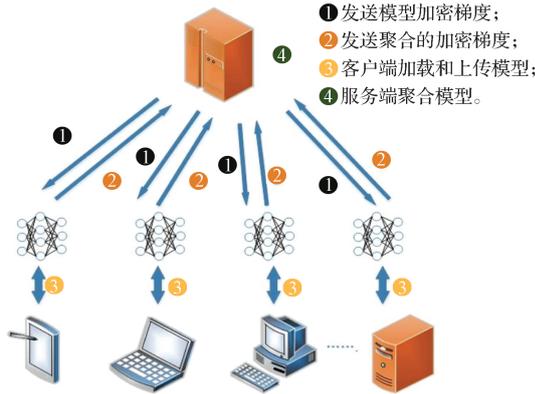


图2 横向联邦学习方式示意图

Fig. 2 Horizontal federated learning mode

实验中通过将数据集进行分配, 替代实验所需要的用户, 数据集分为用户训练集和服务端测试集。因此在开始将数据分配给  $n$  个虚拟用户, 样本大小为  $B$ , 考虑现实中服务端并不是每一次都能将所有用户的训练梯度全部回收, 所以在用户参数的回收当中, 只回收部分用户<sup>[14]</sup>。设参与方的比例为  $C$ , 且用户的选取是完全随机的。服务端控制客户端的模型学习率为  $\eta$ , 并对模型进行初始化, 设模型初始化参数为  $W_0$ ,  $\bar{W}_{t+1}$  为最后一次模型的参数,  $t$  为模型训练轮数。

在模型训练开始时, 服务端需要将模型参数进行初始化操作, 得到初始化模型参数  $W_0$ , 并下放模型; 用户端通过接受服务端下放的模型, 利用自己手中的数据集与服务器下传的模型参数, 并依照服务端的学习率  $\eta$  进行模型训练, 服务端依照参与方的比例  $C$  随机收取  $k$  个用户。

$$k \leftarrow \max(C * n, 1)。 \quad (6)$$

每次被选中的客户端只需将训练后的模型参数上传到服务端, 服务端将接收到的  $W_t^k$  进行模型聚合, 得到新的模型参数, 如式 (7) 所示:

$$\bar{W}_{t+1} = \sum \frac{n_k}{n} W_{t+1}^k。 \quad (7)$$

服务端将聚合赋予服务端模型, 再利用服务端的数据集进行测试, 将服务端模型测试的结果作为评判模型训练标准, 然后服务端将聚合后的“新”模型参数进行下放。在不断循环过程中, 模型将最终趋于一个平衡状态。本文客户端的数据是有限的, 而且在存在数据分配的情况下, 数据的信息量变得更少, 因此课题组限制了模型的通信次数, 防止模型的过拟合。

从上述过程中可以看出, 联邦学习的本质是通过利用服务端的云端计算和用户端的模型参数进行传递, 在保证客户端的数据没有流失的情况下, 进行模型训练。但是该方式模型训练在缺少了大量数据集的

情况下, 只利用单个客户的小型数据集进行模型训练, 而且模型训练过程中, 由于数据集样本过小的问题易导致模型过拟合, 服务端在聚合模型的时候需要舍弃过拟合的客户模型参数训练效果。由于数据集样本的问题, 联邦式的模型训练相比于传统集中式模型的训练效果会有所降低。

## 2 基于联邦学习的 NILM 实验

### 2.1 模型数据集

模型训练使用的数据集采用英国学者搜集的数据 UK\_DALE。UK\_DALE 数据集涵盖 2012 年 11 月到 2015 年 1 月 5 个家庭的大部分电器功率及家庭总功率数据, 其中某一间房子某一周的功率数据就接近 10 GB<sup>[15]</sup>。同时该数据集也是非侵入式电力负荷分解最经典和常用的数据集, 是目前非侵入式电力负荷分解领域最常用的数据集之一。电器的特征主要分为 4 类, 分别是开关型, 如热水壶类等; 多状态类型, 如洗衣机等; 恒定性用电设备, 如电冰箱等; 还有连续性变量设备, 如微波炉等。课题组选取了 5 个具有代表性的电器, 分别是热水壶 (kettle, KT)、洗衣机 (washing machine, WM)、洗碗机 (dishwasher, DW)、冰箱 (fridge, FR) 和微波炉 (microwave, WM)。

### 2.2 数据预处理

#### 2.2.1 模型的映射方式

非侵入式电力负荷分解模型的映射方式一般分为 3 种, 分别为序列对序列的映射 (seq2seq), 序列对子序列的映射 (seq2buseq), 序列对点的映射 (seq2point)<sup>[16-18]</sup>, 如图 3 所示。

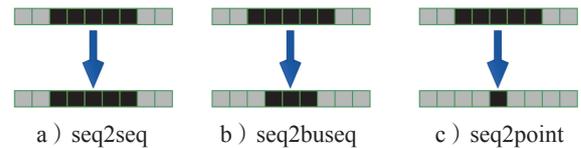


图3 电力负荷分解映射方式

Fig. 3 Mapping method for power load decomposition

$$f_{\text{seq2seq}} : Y_{t-\frac{l}{2}:t+\frac{l}{2}} \rightarrow X_{t-\frac{l}{2}:t+\frac{l}{2}}, \quad (8)$$

$$f_{\text{seq2buseq}} : Y_{t-\frac{l}{2}:t+\frac{l}{2}} \rightarrow X_{t-\frac{l}{4}:t+\frac{l}{4}}, \quad (9)$$

$$f_{\text{seq2point}} : Y_{t-\frac{l}{2}:t+\frac{l}{2}} \rightarrow X_t。 \quad (10)$$

式 (8) ~ (10) 中:  $t$  为窗口中间位置;  $Y$  为家庭总功率;  $X$  为单个电器功率;  $l$  为窗口长度。

选用序列对子序列的映射方式, 因为 seq2buseq 的映射方式既在一定程度上解决了 seq2seq 会随着选用窗口的增长, 模型难以收敛的问题, 也在一定程

度上解决了 seq2point 需要大量计算资源消耗的问题。课题组所选用的 seq2buseq 映射方式通过电器总功率, 预测总功率中所对应电器的功率, 利用总功率前后的功率特性进行预测, 使模型的预测变得更加容易, 同时也减少了计算量<sup>[19]</sup>。

### 2.2.2 数据窗口处理

在数据预处理部分, 电力负荷分解数据主要通过窗口滑动进行数据的选取和截取, 课题组选用序列对应子序列的映射方式进行标签设计, 电器总功率选用 1 024 个单位时间长度, 每个家庭每次截取 1 024 个数据, 作为模型每次输入数据, 相应电器功率截取功率所对应的正中间 512 个时间单位, 每次截取 512 个数据, 作为标签。考虑电器功率与总功率的对应关系, 需要对总功率的数据进行向前填充和向后填充。为确保电器的每次数据只会被计算一次, 窗口滑动设置固定步长, 大小为 512。窗口每次向后移动 512 条数据。这样做既保证了总功率数据的连贯性, 又确保了每个用电设备数据都被作为标签。每个电器的开关状态是训练必不可少的, 因此在数据处理的最终效果中, 需要 50% 的目标电器在使用状态, 所以开关的状态设置比例各占 50%, 即开关的比为 1<sup>[20]</sup>。为了确保模型的可行性, 将 1, 3, 4, 5 号房间的数据集作为训练集, 其他房间数据集作为服务端测试集, 对聚合后的模型进行验证。

### 2.3 模型评判标准

模型训练结果评判采用传统的回归模型评判方式, 本实验主要采用总功率的相对误差 (SAE) 和平均绝对误差 (MAE) 两个指标。MAE 可以真实地反映模型在每时每刻功率分解的真实性, MAE 值越小, 表示该模型对总功率的分解效果越好, 分解的准确率越高。设  $X$  为某电器的真实值,  $\hat{X}_t$  为在该设备中  $t$  时刻的真实功率,  $X_t$  为在该设备中  $t$  时刻模型预测的功率, 则平均绝对误差 (MAE) 可以表示为式 (11)。

$$MAE = \frac{1}{T} \sum_{t=1}^T |\hat{X}_t - X_t|。 \quad (11)$$

SAE 表示一段时间内功率总能量的误差, 其可以表示为一个受异常值影响较小的误差度量, 即特别不准确的孤立预测。SAE 的结果越小, 表示在该模型下, 某个电器在某段时间内的误差越小。该指标也是评判非侵入式电力负荷分解的重要指标之一。设  $r$  为某个电器的总功耗,  $\hat{r}$  为模型预测出的某个电器的总功耗, 其表达式为

$$SAE = \frac{|\hat{r} - r|}{r}。 \quad (12)$$

## 2.4 实验结果与分析

通过选用 5 个电器的负荷分解效果来评估模型效果, 并且选用了几个最为经典的集中式模型与联邦式方法作比较。测试结果如图 4 和表 2 所示。

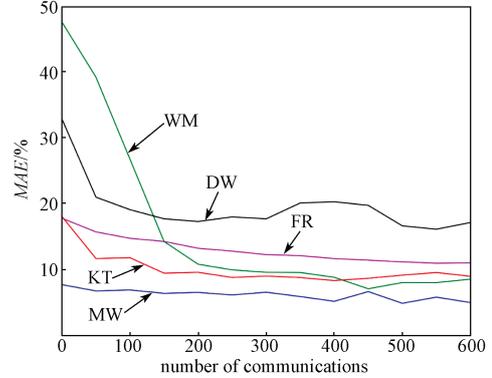


图 4 服务端测试各电器 MAE 与通信次数效果图

Fig. 4 Effect diagram of MAE and communication frequency of each electrical appliance during server testing

表 2 实验测试结果表

Table 2 Experimental test result table

metric	methods	MW	FR	DW	WM	KT
MAE	FL-cGAN	4.94	10.94	17.10	7.07	8.31
	cGAN	3.14	11.86	13.52	7.11	3.59
	seq2point	8.66	20.89	27.70	12.66	7.44
	seq2seq	13.62	24.49	32.52	10.15	9.22
SAE	FL-cGAN	0.009	0.059	0.490	0.017	0.076
	cGAN	0.030	0.070	0.370	0.120	0.026
	seq2point	0.486	0.121	0.645	0.284	0.069
	seq2seq	0.205	0.373	0.779	0.453	0.309

图 4 展示了服务端在不同的通行次数下所得到各个电器的测试 MAE 效果图, 限于数据, 本实验中采用的模拟实验难以实现每一次通信进行一次测试, 所以在实验中将每 50 次通信聚合的实验效果进行一次测试, 并进行保存。考虑到实验中的数据是有限的, 因此在实验中, 通信的次数也进行了限制, 因为实验中, 在有限的的数据下进行多次训练, 有些虚拟客户容易引起模型过拟合, 导致模型质量断崖式下跌。

表 2 展示了各个模型在相同数据集情况下的分解效果。由表 2 的测试结果可以得出, 基于联邦学习的 cGAN 网络 (cGAN network for federated learning, FL-cGAN) 的分解效果会略低于集中式 cGAN 网络模型的分解效果, 但是考虑到数据集的分配情况, 以及联邦学习的 cGAN 网络在每次模型训练时只挑选了部分用户设备的模型参数, 相比于集中网络, 联邦学习的 cGAN 每次训练都减少大部分数据集。相比于传统的大部 seq2seq, 联邦学习的 cGAN 网络模型

的整体效果提升了83%；相比于传统的 seq2point 集中式网络模型，联邦学习的 cGAN 网络模型的整体效果提升了57%。

在 MAE 评价指标中，微波炉和电冰箱在联邦学习的 cGAN 网络要高于集中式的网络模型，考虑数据分配问题，由于这两种电器在家庭中大部分时间都是稳定状态，考虑数据分配时，其对应的数据也是相对稳定的，而且数据的长期稳定性导致模型在预测时也会相对稳定，因此在较少数据的情况下也能拥有较好的结果。在 SAE 评价指标中，联邦学习的 cGAN 的评价效果整体明显优于其他各种集中式网络架构。但是在洗碗机和热水壶的分解效果评价指标上，还是略低于其对应的集中式分解效果，但是相对于其他两种集中式电力负荷分解 seq2point 和 seq2seq，联邦学习的 cGAN 分解效果在 5 种不同电器中基本远高出对应的分解效果。说明联邦学习 cGAN 在预测的准确性和稳健性上优于传统的集中式。

基于联邦学习 cGAN 网络能够完全胜任用户电器功率分解，而且联邦式非侵入式电力负荷分解模型，在确保了用户的相关隐私、保障数据隐私安全及合法合规的基础上，实现了数据共享，并且在数据通信上，联邦式非侵入式电力负荷分解方式极大地减少了数据传输压力。相比于传统电力负荷分解，联邦式非侵入式电力负荷分解更加契合目前的社会发展。

2.5 服务端的模型分解效果图

服务端的模型测试效果如图 5~8 所示。

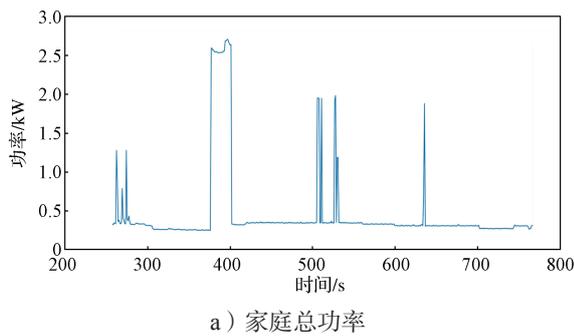


图 5 家庭总功率和微波炉的功率分解效果图  
Fig. 5 Total household power and decomposition effect diagram of microwave ovens power

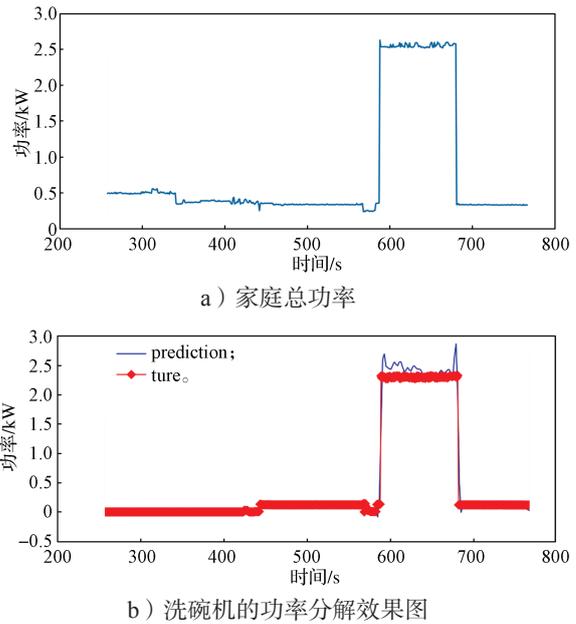


图 6 家庭总功率和洗碗机的功率分解效果图  
Fig. 6 Total household power and dishwasher decomposition effect diagram power

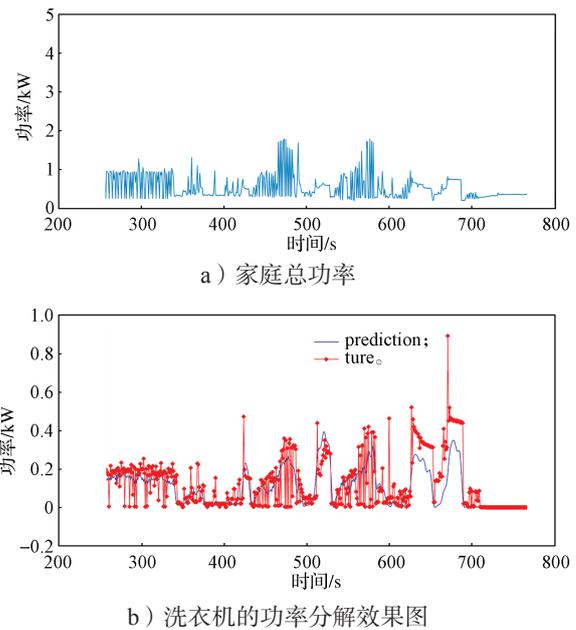
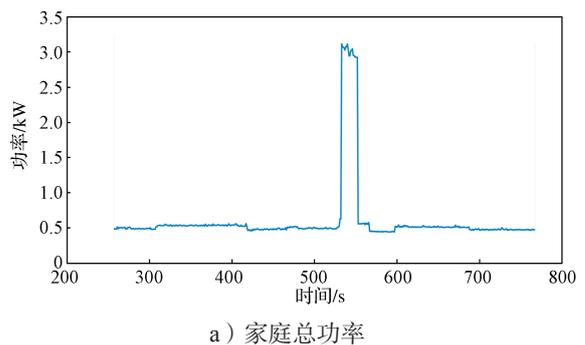
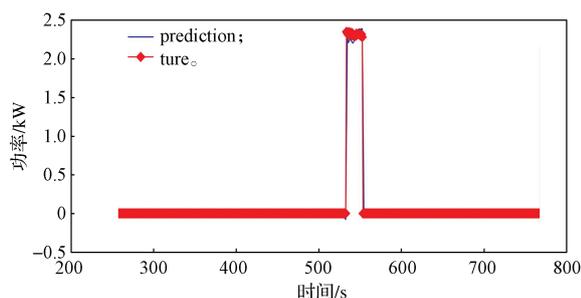


图 7 家庭总功率和洗衣机的功率分解效果图  
Fig. 7 Total household power and decomposition effect diagram of washing machines power





b) 热水壶的功率分解效果图

图8 家庭总功率和热水壶的功率分解效果图

Fig. 8 Total household power and decomposition effect of hot water kettles power

各图模型测试效果中有两张图片, 图 a 是某个时间段家庭的总功率图, 图 b 是在该时间段中某个用电设备的真实功率图和服务端对该用电设备的分解效果图。通过观察 5 个电器的分解效果图可以得出, 在联邦学习的训练方式下, cGAN 网络的非侵入式电力负荷分解达到了期望效果。

### 3 结语

本文提出了联邦学习与传统的非侵入电力负荷分解相结合的一种新型训练模型, 利用联邦式电力负荷分解与 cGAN 网络相结合的方式, 在确保用户隐私的情况下, 进行模型相关训练, 相比于传统集中式的非侵入式电力负荷分解, 所提出的联邦式电力负荷分解模型更加贴近现实生活, 联邦式电力负荷分解更加注重用户的隐私保护, 利用模型的结点参数进行模型更新和传输。文中联邦式电力负荷分解已经能够完成大部分具有明显特征的电器功率相关分解。

下一步的工作, 针对小功率电器设计非侵入式电力负荷分解模型, 将模型与联邦学习方式相结合, 最后将联邦学习非侵入式电力负荷分解模型落地, 将联邦式电力负荷分解引入实际生活当中, 满足客户能真实了解家庭中每个电器的用电情况。

#### 参考文献:

[1] 方祖春, 汪繁荣. 基于非侵入式负荷分解的有色金属冶炼工序识别 [J]. 国外电子测量技术, 2023, 42(1): 170-177.  
FANG Zuchun, WANG Fanrong. Process Identification of Non-Ferrous Metal Smelting Based on Non-Invasive Load Decomposition[J]. Foreign Electronic Measurement Technology, 2023, 42(1): 170-177.

[2] 刘国伟, 马楠, 邓浩, 等. 考虑需求侧管理和网络重构的配电网新能源承载能力评估 [J]. 中国电力,

2023, 56(8): 186-192.

LIU Guowei, MA Nan, DENG Hao, et al. Assessment of New Energy Supportability of Distribution Network Considering Demand Side Management and Network Reconfiguration[J]. Electric Power, 2023, 56(8): 186-192.

- [3] 梁家阁. 基于可变输入 LSTM 和迁移学习的非侵入式电力负荷分解 [D]. 湘潭: 湖南科技大学, 2018.  
LIANG Jiage. Non-Invasive Power Load Decomposition Based on Variable Input LSTM and Migration Learning[D]. Xiangtan: Hunan University of Science and Technology, 2018.
- [4] KELLY J, KNOTTENBELT W. Neural NILM: Deep Neural Networks Applied to Energy Disaggregation[C]// Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments. Seoul: ACM, 2015: 55-64.
- [5] SUN J X, WANG J N, YU W X, et al. Power Load Disaggregation of Households with Solar Panels Based on an Improved Long Short-Term Memory Network[J]. Journal of Electrical Engineering & Technology, 2020, 15(5): 2401-2413.
- [6] MIRZA M, OSINDERO S. Conditional Generative Adversarial Nets[J]. ArXiv Preprint, 2014: 1411.1784.
- [7] AHMED A M A, ZHANG Y, ELIASSEN F. Generative Adversarial Networks and Transfer Learning for Non-Intrusive Load Monitoring in Smart Grids[C]//2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). Tempe: IEEE, 2020: 1-7.
- [8] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative Adversarial Networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [9] RADFORD A, WU J, CHILD R, et al. Language Models Are Unsupervised Multitask Learners[J]. OpenAI Blog, 2019, 1(8): 9.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.
- [11] KAIROUZ P, MCMAHAN H B, AVENT B, et al. Advances and Open Problems in Federated Learning[J]. Found Trends Mach Learn, 2019, 14: 1-210.
- [12] 周毅斌, 肖浩, 裴玮, 等. 基于纵向联邦学习的微电网群协同优化运行与策略进化 [J]. 电力系统自动化, 2023, 47(11): 121-132.  
ZHOU Yibin, XIAO Hao, PEI Wei, et al. Collaborative Optimization Operation and Strategy Evolution of Microgrid Cluster Based on Vertical Federated Learning[J]. Automation of Electric Power Systems,

2023, 47(11): 121-132.

[13] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-Efficient Learning of Deep Networks from Decentralized Data[EB/OL]. [2013-12-23]. <https://arxiv.org/abs/1602.05629v4>.

[14] REISIZADEH A, MOKHTARI A, HASSANI H, et al. FedPAQ: A Communication-Efficient Federated Learning Method with Periodic Averaging and Quantization[J]. ArXiv, 2019. DOI:10.48550/arXiv.1909.13014.

[15] KELLY J, KNOTTENBELT W. The UK-DALE Dataset, Domestic Appliance-Level Electricity Demand and Whole-House Demand from Five UK Homes[J]. Scientific Data, 2015, 2: 150007.

[16] 王 轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解 [J]. 中国电机工程学报, 2019, 39(1): 75-83, 322.  
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Nonintrusive Load Monitoring Based on Sequence-to-Sequence Model with Attention Mechanism[J]. Proceedings of the CSEE, 2019, 39(1): 75-83, 322.

[17] PAN Y G, LIU K, SHEN Z Y, et al. Sequence-to-Subsequence Learning with Conditional Gan for Power Disaggregation[C]//2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona: IEEE, 2020: 3202-3206.

[18] ZHANG C Y, ZHONG M J, WANG Z Z, et al. Sequence-to-Point Learning with Neural Networks for Non-Intrusive Load Monitoring[C]//National Conference on Artificial Intelligence. Toronto: AAAI Press, 2018, 32(1): 2604-2611.

[19] VERMA A, ANWAR A, PARVEZ MAHMUD M A, et al. A Comprehensive Review on the NILM Algorithms for Energy Disaggregation[EB/OL]. [2013-12-23]. <https://arxiv.org/abs/2102.12578v2>.

[20] BATRA N, KELLY J, PARSON O, et al. NILMTK: an Open Source Toolkit for Non-Intrusive Load Monitoring[EB/OL]. [2013-12-23]. <https://arxiv.org/abs/1404.3878v1>.

(责任编辑: 申 剑)



(上接第 30 页)

[9] 马力遥. 基坑多级支护受力与变形机理及破坏模式分析 [D]. 天津: 天津大学, 2021.  
MA Liyao. Analysis of Stress and Deformation Mechanism and Failure Mode of Multi-level Support in Foundation Pit[D]. Tianjin: Tianjin University, 2021.

[10] 曹程明, 时轶磊, 龙 照, 等. 偏压条件下排桩加内支撑支护深基坑受力与变形分析[J]. 科学技术与工程, 2023, 23(7): 2952-2959.  
CAO Chengming, SHI Yilei, LONG Zhao, et al. Stress and Deformation Analysis of Deep Foundation Pit Supported by Pile and Internal Bracing Under Unsymmetrical Loaded[J]. Science Technology and Engineering, 2023, 23(7): 2952-2959.

[11] 何剑峰. 建筑工程深基坑支护结构选型原则与应用 [J]. 四川水泥, 2022(11): 200-202.  
HE Jianfeng. Principles and Application of Deep Foundation Pit Support Structure Selection in Construction Engineering[J]. Sichuan Cement, 2022(11): 200-202.

[12] 辜飘云. 基坑中排桩与斜撑组合支护结构的应用研究 [D]. 南昌: 南昌大学, 2021.  
GU Piaoyun. Study on Application of Combined Supporting Structure of Row Piles and Diagonal Bracing in Foundation Pit[D]. Nanchang: Nanchang University, 2021.

[13] 唐海亮. 基于修正莫尔库伦模型的基坑开挖变形及受力分析 [D]. 昆明: 云南大学, 2017.  
TANG Hailiang. Deformation and Stress Analysis of Foundation Pit Excavation Based on Modified Mohr Coulomb Model[D]. Kunming: Yunnan University, 2017.

(责任编辑: 姜利民)