

DOI: 10.19783/j.cnki.pspc.231013

# 数据孤岛下基于联邦学习的用户电价响应刻画及其应用

李锦辉<sup>1</sup>, 吴毓峰<sup>1</sup>, 余涛<sup>1,2</sup>, 潘振宁<sup>1</sup>

(1. 华南理工大学电力学院, 广东 广州 510640; 2. 广东省电网能量测与先进计量企业重点实验室, 广东 广州 510640)

**摘要:** 电价型需求响应离不开对用户价格响应的精准刻画, 然而用户对价格的响应大多发生在与聚合商的交互中。并且出于隐私保护需求, 这些交互数据往往不被公开, 呈现为数据孤岛。针对现阶段用户数据隐私需求和电网调度需求相互冲突的问题, 提出了基于联邦学习的用户电价响应行为刻画及其应用方法。首先, 构建基于联邦学习的用户电价响应行为刻画的分布式交互框架, 将原始数据信息交互转变为特征信息交互。然后, 利用差分隐私-联邦近端算法实现不同聚合商电价响应模型的参数聚合, 获得区域用户电价响应模型。最后, 提出嵌入响应模型的配电网优化运行应用方法, 利用改进的策略近端优化算法求解系统实时电价和储能出力。算例表明, 所提方法在保障用户用能信息隐私下, 能准确刻画区域用户电价响应行为, 并改善配电网综合效益。

**关键词:** 电价型需求响应; 用户隐私; 联邦学习; 强化学习

## Characterization of user price response behavior and its application based on federated learning considering a data island

LI Jinhui<sup>1</sup>, WU Yufeng<sup>1</sup>, YU Tao<sup>1,2</sup>, PAN Zhenning<sup>1</sup>

(1. School of Electric Power, South China University of Technology, Guangzhou 510640, China; 2. Guangdong Provincial Key Laboratory of Intelligent Measurement and Advanced Metering of Power Grid, Guangzhou 510640, China)

**Abstract:** Price-based demand response cannot live without accurate characterization of user response, but these data mostly exist in the interaction between the demand response aggregator and users. Because of the imperative of privacy protection, the data often remains confidential, manifesting as isolated data islands. In response to the current problem where user data privacy requirements clash with the demands of grid scheduling, this paper proposes a method for characterizing user electricity price response behavior based on federated learning and its application. Initially, a distributed interactive framework for characterizing user electricity price response behavior through federated learning is established, transforming raw data information into feature-based interactions. Subsequently, a differential privacy-federated proximal algorithm is employed to aggregate parameters from various utility providers' electricity price response models, resulting in a regional user electricity price response model. Finally, an application method for optimizing the operation of the distribution network is presented by embedding the response model. An improved strategy proximal optimization algorithm is used to determine real-time electricity prices and energy storage output. Case studies confirm that the proposed approach accurately characterizes regional user electricity price response behavior while preserving the privacy of user energy consumption information and enhancing the overall efficacy of the distribution network.

This work is supported by the National Natural Science Foundation of China (No. 52207105).

**Key words:** price-based demand response; users' privacy; federated learning; reinforcement learning

## 0 引言

电力需求响应(demand response, DR)指电力市场

**基金项目:** 国家自然科学基金项目资助(52207105); 国家自然科学基金委员会-国家电网公司智能电网联合基金项目资助(U2066212); 中国博士后科学基金项目资助(2022M721184)

价格发生明显变化或系统可靠性存在风险时, 电力用户根据价格或激励措施, 改变用电计划, 从而促进电力供需平衡、保障电网稳定运行<sup>[1-5]</sup>。其中, 由于管理的便捷性, 价格型需求响应被认为是一种具有前景的方式<sup>[6-7]</sup>。如何准确刻画用户对电价的响应行为是该模式运行的基础, 该课题也一直是需求响应领域的研究热点。按是否基于数学模型, 当前响

应行为刻画的研究可分为2类: 基于模型的刻画方法和无模型的数据驱动方法。

基于模型的刻画方法中, 以应用最为广泛的价格弹性为例, 用户对电价的响应通常被简化为具备固定结构的线性或二次函数。文献[8]利用价格弹性矩阵表征负荷受电价影响程度, 实现综合能源系统的优化调度; 文献[9]则提出了基于弹性效应权重的改进价格弹性矩阵模型, 分析不同时段的影响, 有效减小峰谷差; 文献[10-11]根据用户的消费者心理学原理构建负荷响应不确定性模型, 例如补偿电价灵敏度、价格分区表示等, 最后利用线性规划软件优化系统运行。这种方式依赖预先框定的用户响应函数形式, 当这种函数形式与用户真实响应行为存在较大出入时, 难以保证其有效性。

无模型的数据驱动方法一定程度上解决了上述问题。文献[12]基于先进的非侵入式技术, 利用改进的循环神经网络拟合实际数据, 并提出了需求侧智能动态定价机制; 文献[13-15]则根据历史积累的大量数据, 提出改进的深度学习模型, 例如融合特征提取的时序预测网络、改进的注意力机制等, 考虑电价、气象等数据影响, 搭建模型以表征用户响应程度。可见这类方法从数据出发, 更准确地刻画了用户对价格的响应行为, 但当前这类方法依赖于完备的“价格-功率”数据基础, 即需悉知所有用户对电价的功率响应数据。且无模型的方法所得响应行为刻画难以解析化表达, 通常依赖于低效的启发式算法才可融入配电网需求响应运行优化中。

实际上, 终端用户对价格的响应行为大多发生在与售电公司等聚合商(load aggregator, LA)主体的交互中。然而, 我国的电力零售市场建设尚未完善, 当前仅有部分终端用户参与了聚合商为主导的零售市场, 大部分用户依然以相对稳定的计划电价进行购电, 未能积累有效的电价响应数据。此外, 出于用户隐私及商业竞争考虑, 各聚合商的数据通常难以共享, 表现为独立的数据孤岛。因此, 电网运营商当前阶段开展电价型需求响应面临着部分用户无数据可用, 部分用户数据不共享的情况。在此背景下, 本文主要讨论如何合理利用数据孤岛已有信息, 刻画区域用户普适的电价响应行为, 实现配网需求响应定价, 并考虑配网储能和发电机组经济成本, 同时对其运行进行优化, 提升系统供需双侧资源协调优化。具体而言, 本文提出了数据孤岛下基于联邦学习的用户电价响应刻画及其应用方法, 集中于解决2个技术问题: 1) 在数据孤岛下, 如何发挥数据驱动方法的优势实现用户响应行为的有效刻画; 2) 如何利用用户响应行为刻画结果, 形成快速有效

的配网需求响应定价及运行优化策略。文章贡献点可总结如下。

1) 提出数据孤岛下用户电价响应行为刻画的分布式交互框架。基于联邦学习(federated learning, FL), 将原始信息的交互转化为了特征参数的交互。在聚合商不公开用户电价的前提下, 即可实现区域终端用户电价响应行为的刻画, 有效地保障了用户隐私与聚合商利益。

2) 设计隐私加强的联邦学习算法。考虑参数上传存在隐私泄露的风险, 提出了基于差分隐私的联邦近端算法(differential private-federated proximal, DP-FedProx)。通过引入近端项, 解决终端数据不平衡问题, 并通过加噪处理进一步加强用户电价响应行为刻画过程中的隐私保护。

3) 构建配网需求响应定价及储能运行优化的强化学习方法。基于所得区域电价响应行为刻画结果构建强化学习环境, 制定实时电价调整用户用电, 并配置储能和发电机组的出力, 提高系统运行经济性和调控灵活性。其中, 引入的改进近端策略优化算法, 有效提高了算法收敛性和数据利用率。

## 1 系统实施框架与步骤

本文系统实施架构包含负荷聚合商及独立用户、配电网运营商(distribution system operator, DSO)及其配置的储能和发电机组构成, 其中, 配电网运营商充当联邦学习的主导者和发起者, 协调和管理各个聚合商之间的模型训练过程, 其目的为获取综合模型对区域用户电价响应行为进行有效刻画, 并依此对配网实时电价及储能出力进行优化, 激发用户的需求响应潜力以实现配网运行质量的提升。负荷聚合商直接向上级电力批发市场购售电, 并与签约用户进行代理电价交互, 积累了大量用户历史响应数据, 即“代理电价-响应功率”数据。如上所述, 出于利益及隐私保护, 各聚合商间为独立的数据孤岛, 其作为客户端训练本地模型并参与到联邦学习的训练中。系统运行实施框架如图1所示。首先, 聚合商收集获取历史上用户对电价的直接响应数据, 如图1过程①所示。其次, 聚合商和DSO依托于联邦学习框架开展模型训练, 如图1过程②所示。其中, 聚合商参与到由配电网运营商主导的联邦学习框架中, 其各自利用本地数据对DSO发布的综合模型进行再训练, 并通过特定处理, 将所得参数更新结果加噪上传至DSO中。DSO则综合所有聚合商上传的信息对综合模型进行更新。经过多次迭代最终得到收敛的综合模型, 即区域用户电价响应刻画结果。显然, 这种分布式训练方式有效减

少了中心计算压力并且保护了用户隐私。最后，如图1过程③所示，DSO将所得区域用户电价响应刻画结果以等式约束形式写入配电网电价型需求响应优化问题，并构建强化学习环境，实现区域配网未加入聚合商用户的电价优化求解<sup>[16]</sup>。

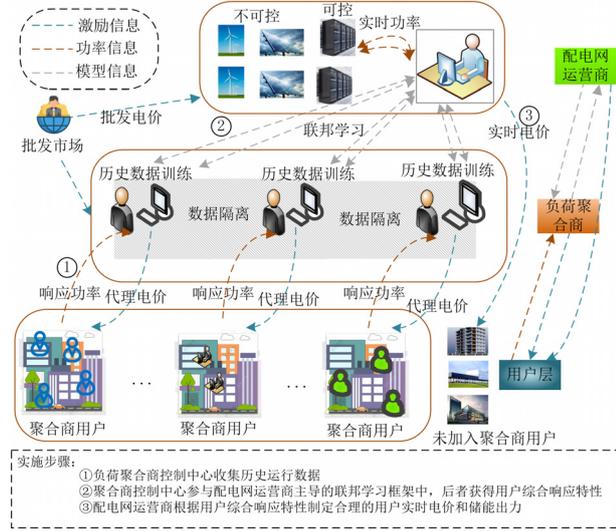


图1 系统结构与实施步骤

Fig. 1 System structure and implement steps

显然，所提框架需要聚合商配合构建各自本地模型及分享模型部分参数。对于前者，聚合商有动力构建本地模型以优化代理电价的制定<sup>[17]</sup>。而对于后者，区域用户综合模型可帮助聚合商了解当前区域用户的行为模式，以形成更具吸引力的合约激励用户加入聚合商调控<sup>[18-19]</sup>。因此，聚合商具备充足的动力参与所提框架的互动过程。

## 2 基于 FL 框架的用户电价响应行为刻画

### 2.1 用户决策模型

考虑到当前尚未形成可靠的用户电价型需求响应公开数据集，且未来用户用电将向智能化方向发展<sup>[20]</sup>，故参考现有研究，构建用户决策模型以模拟用户电价响应行为<sup>[15]</sup>。本文中，各用户负荷由基础负荷和可中断负荷两部分构成，且假定其行为是足够理性的。用户通过调节内部用电计划，实现优化周期内的综合用电成本最小，其中约束表示为

$$P_{load,t}^{LA} = P_{shave,t}^{LA} + P_{base,t}^{LA} \quad (1)$$

$$P_{shave,min,t}^{LA} \leq P_{shave,t}^{LA} \leq P_{shave,max,t}^{LA} \quad (2)$$

式中： $P_{load,t}^{LA}$  表示  $t$  时段负荷聚合商购电量； $P_{shave,t}^{LA}$  表示削减负荷； $P_{base,t}^{LA}$  表示基础用电负荷； $P_{shave,max,t}^{LA}$ 、 $P_{shave,min,t}^{LA}$  分别为可削减负荷的最大、最小值。

聚合商目标为综合用电成本  $F^{LA}$  最小，表示如

式(3)所示。

$$\min F^{LA} = C_t^{LA} - U_t^{LA} \quad (3)$$

式中： $C_t^{LA}$  表示用户的运行成本； $U_t^{LA}$  表示用户用能效用，各部分的计算为

$$C_t^{LA} = \lambda_t P_{load,t}^{LA} \quad (4)$$

$$U_t^{LA} = \alpha P_{load,t}^{LA} - \beta P_{load,t}^{LA^2} \quad (5)$$

式中： $\lambda_t$  为电价； $\alpha$ 、 $\beta$  均为用户偏好系数。

此模型描述了单时间断面下用户受电价影响的负荷变化。本文随机生成各用户模型参数，并取电价为模型输入，负荷为输出，模拟聚合商与用户间的交互，在聚合商侧生成大量“电价-功率”数据。

### 2.2 基于差分隐私-联邦学习的用户响应行为刻画

如图1所示，本文采用联邦学习来解决聚合商间数据隔离的问题，其中联邦学习当前已在电力系统故障诊断<sup>[21]</sup>、负荷预测<sup>[22]</sup>、运行优化<sup>[23]</sup>领域得到应用，其原理本文不再赘述。但需要注意，不同于上述以单一具体系统为对象的应用，各聚合商下用户的数量、体量都存在着显著差别，基于传统联邦学习的训练方式将难以平衡各聚合商的数据，收敛困难<sup>[23]</sup>。同时，聚合商本地模型的参数实际上即蕴含了其用户对电价的响应特性，故参数的交互也会带来隐私泄露的风险<sup>[24]</sup>。因此，为应对数据不平衡问题并加强在联邦学习过程中的隐私保护，本文引入了差分隐私-联邦近端算法来刻画用户的响应行为，将图1中过程②拓展为图2所示。

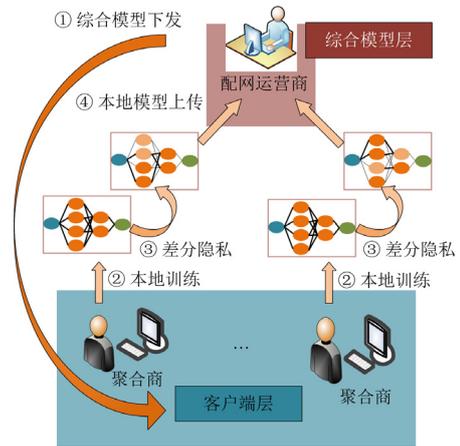


图2 差分隐私-联邦近端算法结构图

Fig. 2 Structure of DP-FedProx

其中，各聚合商本地模型训练中损失函数中应引入近端项，使得本地更新模型时尽可能地靠近综合模型，从而减小客户端层聚合商间的数据异构性的影响，同时加快综合模型的收敛速度。差分隐私主要对传输的信息加噪，防止外部攻击者通过模型

参数获得用户原始数据信息, 加强了隐私保护性。

### 2.2.1 聚合商本地用户响应行为刻画模型训练

本文根据式(1)一式(5)刻画本地用户决策模型构建数据集, 并用神经网络训练数据得到聚合商本地用户响应行为刻画模型。联邦学习的目的在于通过多方合作, 获得不同用户理性决策下的统一行为模型。但各聚合商旗下用户存在差异, 若各本地模型直接以刻画本地用户行为为目的进行训练, 将难免使得各模型训练方向不一, 差异过大, 影响最终综合模型的形成。故有必要调整本地模型的训练方向, 以保障综合模型的收敛。为此, 在本地用户行为拟合损失外, 各本地模型的损失函数引入与综合模型的距离惩罚作为近端项, 确保模型更新方向与综合模型一致。本地网络模型在第  $k$  轮迭代时的训练目标函数  $\min_{\omega_{k,l}} h_k$  如式(6)所示。

$$\min_{\omega_{k,l}} h_k(\omega_{k,l}; \omega_l) = f_k(\omega_{k,l}) + \frac{\mu}{2} \|\omega_{k,l} - \omega_l\|^2 \quad (6)$$

式中:  $h_k$  为聚合商  $k$  的模型训练函数;  $\omega_{k,l}$  为聚合商  $k$  与配网运营商进行第  $l$  次参数交互的模型参数,  $k=1,2,\dots,N_{LA}$ ,  $N_{LA}$  为聚合商数量,  $l=1,2,\dots,l_{\max}$ ,  $l_{\max}$  为最大交互轮次;  $\omega_l$  为综合模型参数, 即配网运营商模型;  $f_k(\cdot)$  为聚合商  $k$  数据训练的损失函数, 一般用均方误差表示;  $\mu$  为一个正则化参数, 表征近端项的权重大小,  $\mu \in (0, \infty)$ ;  $\|\omega_{k,l} - \omega_l\|^2$  为近端项, 表示聚合商模型参数与配网运营商模型参数的平方差异, 作为训练惩罚项, 约束二者的差距。

实际上, 聚合商一方面需要掌握本地用户响应以指导聚合商代理电价的制定, 另一方面需要学习其他聚合商下的用户行为以辅助其吸引新用户加入。因此, 式(6)近端项的存在可以被聚合商接受。

同时, 为有效利用本地模型促进综合模型的更新, 引入非精确解,  $\gamma$  为非精确解系数,  $\gamma \in [0, 1]$ , 设置提前退出训练的条件, 当本地模型参数满足式(7)时, 则认为此次训练完成。

$$\|\nabla h_k(\omega_{k,l}; \omega_l)\| \leq \gamma \|\nabla h_k(\omega_l; \omega_l)\| \quad (7)$$

式中: “ $\nabla$ ” 为梯度算子;  $\gamma$  越小表示模型训练完成度越高; 符号 “ $\|\cdot\|$ ” 为一范数公式。

此外, 为避免本地模型参数的传递间接泄露本地用户的行为。对此, 在聚合商本地模型参数中添加噪声, 并在训练过程中应用差分隐私算法<sup>[16]</sup>, 具体如式(8)一式(10)所示。

$$\mathbf{g}_{k,l+1} = \nabla f_k(\omega_{k,l+1}^E) + \mu \|\omega_{k,l+1}^E - \omega_l\|_2 \quad (8)$$

$$\tilde{\mathbf{g}}_{k,l+1} = \mathbf{g}_{k,l+1} / \max(1, \|\mathbf{g}_{k,l+1}\|_2 / C) \quad (9)$$

$$\bar{\mathbf{g}}_{k,l+1} = \tilde{\mathbf{g}}_{k,l+1} + N(0, z^2 C^2) \mathbf{I} \quad (10)$$

式中:  $\mathbf{g}_{k,l+1}$  为聚合商  $k$  网络模型梯度;  $\omega_{k,l+1}^E$  为聚合商  $k$  模型进行的第  $E$  次训练; 符号 “ $\|\cdot\|_2$ ” 为二范数公式, 使得变量间维度对齐;  $\|\mathbf{g}_{k,l+1}\|_2$  为梯度更新量;  $\tilde{\mathbf{g}}_{k,l+1}$  为中间变量;  $\max(\cdot)$  函数为括号中取最大值;  $C$  为模型梯度敏感度, 用于限制每个样本产生的梯度更新量, 以控制个体数据对整体的影响;  $\bar{\mathbf{g}}_{k,l+1}$  为最终的梯度更新量;  $N(0, z^2 C^2)$  是均值为 0, 方差为  $z^2 C^2$  的随机量,  $z$  为噪声乘子;  $\mathbf{I}$  为单位矩阵。

最终聚合商模型根据式(11)完成本地模型梯度更新。

$$\omega_{k,l+1}^{E+1} = \omega_{k,l+1}^E - \eta \bar{\mathbf{g}}_{k,l+1} \quad (11)$$

式中,  $\eta$  为参数学习率。

### 2.2.2 区域用户响应行为刻画的综合模型更新

配网运营商侧旨在利用聚合商侧本地模型形成可刻画区域用户的综合模型。考虑到聚合商下属用户数量存在差异, 各本地模型对于区域用户的代表性有所不同。因此, 此处采用梯度加权平均方法, 将聚合商模型的训练样本数量作为权重, 加权计算所有上传的梯度参数作为综合模型  $\omega_{l+1}$ , 如式(12)所示。

$$\omega_{l+1} = \sum_{k=1}^{N_{LA}} \frac{m_k \omega_{k,l+1}}{M} \quad (12)$$

式中:  $m_k$  为聚合商  $k$  样本数量;  $M$  为所有聚合商的总样本个数,  $M = \sum_{k=1}^{N_{LA}} m_k$ 。需要说明的是, 当最终更新完成后, 得到区域用户响应模型  $\omega$ 。

### 2.2.3 差分隐私-联邦学习算法步骤

综上, 所提差分隐私的联邦近端算法的步骤如图 3 所示, 展示了联邦学习和隐私机制的建立流

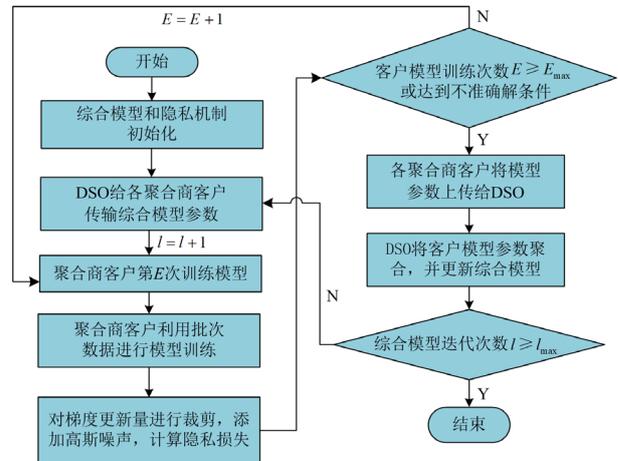


图 3 差分隐私-联邦近端算法步骤图

Fig. 3 Steps of DP-FedProx

程, 在本地计算中引入差分隐私机制, 可以令训练系统达到更高级别的隐私保护。

### 3 基于强化学习的电价型需求响应调度应用

#### 3.1 近端策略优化算法

显然, 区域用户响应行为刻画所得结果为神经网络模型, 难以用解析式的方式应用于配电网优化运行任务中。因此, 以启发式算法和强化学习算法为代表的人工智能方法成为区域用户响应行为模型应用的选择。其中, 启发式算法多是基于直观或经验构造的算法, 基本思路在于通过大量待验证解的多次迭代更新以获得一个可接受的可行解。但其需要消耗大量时间用于搜索更新, 难以应用于配电网的实时优化运行<sup>[25-26]</sup>。而强化学习则利用“离线训练, 在线运行”的方式, 在运行日之前, 将预测信息或可能出现的情况进行仿真训练, 让模型学习到最优策略。这个策略可以表示成策略网络或价值网络。日内运行时系统可以根据最优策略快速得到最优解。综上, 考虑利用强化学习框架将区域用户响应行为融入配网运行优化。

其中, 以策略梯度算法为代表的经典强化学习算法, 利用奖励上升的梯度方向进行策略优化, 其不足在于容易收敛到局部最小值和数据使用效率低。因此, 基于演员-评论家框架的改进近端策略优化算法(proximal policy optimization 2, PPO2)<sup>[27]</sup>得到广泛关注, 其通过对样本进行多次利用, 提高了模型全局收敛性。具体而言, PPO2 算法利用新旧策略的比例来限制策略的更新范围, 确保策略朝着梯度下降方向有效更新的同时, 又不会更新太大导致算法性能下降。同时, 采用裁断方法来减小新旧策略的差异, 其具体实现方式可参考文献[28], 此处仅对 PPO2 算法的主要公式进行展示说明。策略网络  $\theta_{g+1}$  和价值网络  $\phi_{g+1}$  的第  $g+1$  次更新表达式分别如式(13)和式(14)所示。

$$\theta_{g+1} = \arg \max_{\theta} \frac{1}{|D_g|} \sum_{\tau \in D_g} \sum_{t=0}^T \min \left[ \frac{\pi_{\theta}(a_t | s_t)}{\pi_{\theta_g}(a_t | s_t)} \cdot A^{\pi_{\theta_g}}(s_t, a_t), g(\varepsilon, A^{\pi_{\theta_g}}(s_t, a_t)) \right] \quad (13)$$

$$\phi_{g+1} = \arg \min_{\phi} \frac{1}{|D_g|} \sum_{\tau \in D_g} \sum_{t=0}^T (V_{\phi}(s_t) - R_t)^2 \quad (14)$$

式中:  $\theta$  为策略网络;  $|D_g|$  为第  $g$  次更新的轨迹数量;  $T$  为强化学习训练的轨迹长度;  $\tau$  为轨迹集合  $D_g$  的其中一个轨迹;  $\pi_{\theta}(a_t | s_t)$  和  $\pi_{\theta_g}(a_t | s_t)$  分别为在当前状态  $s_t$  下选择动作  $a_t$  的新策略  $\pi_{\theta}$  和旧策略  $\pi_{\theta_g}$ ;  $A^{\pi_{\theta_g}}(\cdot)$  为旧策略下的优势函数, 用于更新策

略网络;  $g(\cdot)$  为裁剪函数, 作用是在裁剪参数  $\varepsilon$  下限制约束旧策略的优势函数值;  $V_{\phi}(s_t)$  为当前状态  $s_t$  下价值网络  $\phi$  的估计价值;  $R_t$  为即时的奖励。

#### 3.2 电价型需求响应下配电网优化运行模型

为求解配电网实时电价和储能等设备出力, 将问题设计成强化学习框架对应的状态空间、动作空间和奖惩函数。将 2.2 节所提基于 FL 框架的区域用户电价响应行为综合模型写成等式函数, 并将其应用到强化学习的环境中<sup>[29]</sup>。最终, 形成需求响应调度应用的强化学习框架如图 4 所示。

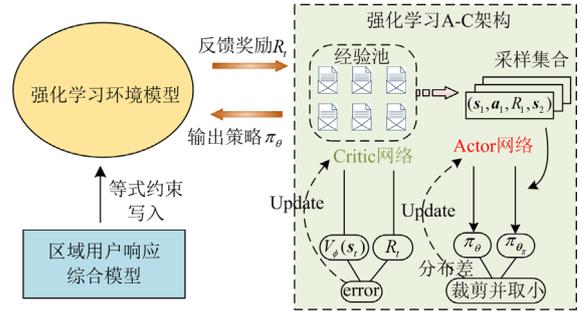


图 4 基于强化学习的需求响应调度应用

Fig. 4 Scheduling application of reinforcement learning-based demand response

##### 3.2.1 状态空间

对于任意  $t$  时段, 状态空间  $s_t$  由各节点  $i$  的新能源出力值  $P_{i,pv,t}$ 、固定负荷有功功率  $P_{conload,t}$ 、储能荷电状态  $E_{i,ess,t}^{SOC}$ 、发电机组出力上限  $P_{i,mt,max}$  和时段  $t$  共同构成, 如式(15)所示。

$$s_t = \{P_{i,pv,t}, P_{conload,t}, E_{i,ess,t}^{SOC}, P_{i,mt,max}, t\} \quad (15)$$

##### 3.2.2 动作空间

考虑配电网运营商拥有自主产权的储能和发电机组, 并且可以通过设定实时电价来影响独立用户的用能行为。因此, 文章将储能和发电机组出力与实时电价设置为动作空间  $a_t$ , 并通过约束条件限制动作空间的范围。

$$a_t = \{P_{i,ess,t}, P_{i,mt,t}, p_t\} \quad (16)$$

式中:  $P_{i,ess,t}$  为电储能的有功功率;  $P_{i,mt,t}$  为发电机组的有功功率;  $p_t$  为  $t$  时段的实时电价。

##### 3.2.3 奖惩函数

每个时段下智能体会根据策略生成动作, 根据区域用户行为刻画模型得到用户出力, 并进一步计算相应的单步奖励。此处, 文章的奖惩函数由配电网的收益奖励和运行成本组成。

实际上, 负荷聚合商具有内部调度功能, 且和 DSO 一样需在批发市场提供报价和数量信息, 以便

在市场中购售电量。因此负荷聚合商和 DSO 按照批发电价购买电量, DSO 制定的实时电价仅可影响独立用户响应行为。为了突出区域用户响应行为综合模型并加以应用, 将其看成独立用户, 并带入强化学习环境中。DSO 的收益奖励  $r_{i,1}$  为配电网向上层电网购买电量的成本费用与向用户出售电量费用之差构成, 如式(17)所示。

$$r_{i,1} = p_t P_{\text{load},t} - P_{\text{grid},t} \rho_{\text{grid},t} \quad (17)$$

式中:  $P_{\text{load},t}$  为负荷功率;  $P_{\text{grid},t}$  为配网购电功率;  $\rho_{\text{grid},t}$  为批发市场购电单价。

运行成本  $r_{i,2}$  由储能的老化成本  $C_{i,\text{ess},t}$  和发电机组能源消耗成本  $C_{i,\text{mt},t}$  组成。具体定义如式(18)一式(20)所示。

$$r_{i,2} = \sum_{i \in I} (C_{i,\text{ess},t} + C_{i,\text{mt},t}) \quad (18)$$

$$C_{i,\text{ess},t} = \beta_{i,\text{ess}} \eta_{i,\text{ess}} P_{i,\text{ess},t}^2 \quad (19)$$

$$C_{i,\text{mt},t} = \beta_{i,\text{mt},a} P_{i,\text{mt},t}^2 + \beta_{i,\text{mt},b} P_{i,\text{mt},t} + \beta_{i,\text{mt},c} \quad (20)$$

式中:  $I$  为所有节点集合;  $\beta_{i,\text{ess}}$  为节点  $i$  储能老化成本系数;  $\beta_{i,\text{mt},a}$ 、 $\beta_{i,\text{mt},b}$ 、 $\beta_{i,\text{mt},c}$  均为发电机组的成本系数。

综上所述, 强化学习的单步奖励函数  $r_t$  如式(21)所示。

$$r_t = r_{i,1} - r_{i,2} \quad (21)$$

### 3.2.4 约束条件

模型约束包括线性潮流约束、向电网购电约束、储能设备运行约束、负荷约束和价格约束。

式(22)一式(27)为线性交流潮流计算方法, 式(28)和式(29)为潮流安全约束, 如下所示。

$$P_{ij,t} = k_{ij,1} (U_{i,t} - U_{j,t}) / x_{ij} + k_{ij,2} (\delta_{i,t} - \delta_{j,t}) / x_{ij} \quad (22)$$

$$Q_{ij,t} = -k_{ij,1} (\delta_{i,t} - \delta_{j,t}) / x_{ij} + k_{ij,2} (U_{i,t} - U_{j,t}) / x_{ij} \quad (23)$$

$$P_{i,t} = \sum_{\substack{j=1 \\ j \neq i}}^{N_B} [k_{ij,2} (\delta_{i,t} - \delta_{j,t}) / x_{ij} + k_{ij,1} (U_{i,t} - U_{j,t}) / x_{ij}] \quad (24)$$

$$Q_{i,t} = \sum_{\substack{j=1 \\ j \neq i}}^{N_B} [k_{ij,1} (\delta_{j,t} - \delta_{i,t}) / x_{ij} + k_{ij,2} (U_{i,t} - U_{j,t}) / x_{ij}] \quad (25)$$

$$k_{ij,1} = r_{ij} x_{ij} / (r_{ij}^2 + x_{ij}^2) \quad (26)$$

$$k_{ij,2} = x_{ij}^2 / (r_{ij}^2 + x_{ij}^2) \quad (27)$$

$$-P_{ij,\text{max}} \leq P_{ij,t} \leq P_{ij,\text{max}} \quad (28)$$

$$U_{i,\text{min}} \leq U_{i,t} \leq U_{i,\text{max}} \quad (29)$$

式中:  $P_{ij,t}$  和  $Q_{ij,t}$  分别为  $t$  时段节点  $i$ 、 $j$  间的有功和无功功率;  $r_{ij}$ 、 $x_{ij}$  分别为节点  $i$ 、 $j$  间的电阻和

电抗;  $P_{i,t}$ 、 $Q_{i,t}$ 、 $U_{i,t}$ 、 $\delta_{i,t}$  分别为  $t$  时段节点  $i$  的有功功率、无功功率、电压和相角;  $N_B$  为支路数量;  $P_{ij,\text{max}}$  为节点  $i$ 、 $j$  间传输的有功功率最大值;  $U_{i,\text{max}}$  和  $U_{i,\text{min}}$  分别为节点  $i$  最大和最小电压。配电网内节点  $i$  在  $t$  时段的有功功率  $P_{i,t}$  和无功功率  $Q_{i,t}$  如式(30)和式(31)所示。

$$P_{i,t} = P_{i,\text{mt},t} + P_{i,\text{pv},t} + P_{i,\text{ess},t} - P_{i,\text{conload},t} - P_{i,\text{adload},t} \quad (30)$$

$$Q_{i,t} = Q_{i,\text{mt},t} - Q_{i,\text{conload},t} \quad (31)$$

式中:  $P_{i,\text{mt},t}$ 、 $P_{i,\text{pv},t}$  和  $P_{i,\text{ess},t}$  分别为  $t$  时段节点  $i$  的发电机组、新能源和电储能的有功出力值;  $P_{i,\text{conload},t}$  和  $P_{i,\text{adload},t}$  分别为固定有功负荷和响应有功负荷;  $Q_{i,\text{mt},t}$ 、 $Q_{i,\text{conload},t}$  分别为发电机组无功功率和固定负荷的无功值。

考虑电网的运行稳定性, 与上层电网交互功率  $P_{\text{grid},t}$  约束为

$$P_{\text{grid},\text{min}} \leq P_{\text{grid},t} \leq P_{\text{grid},\text{max}} \quad (32)$$

式中,  $P_{\text{grid},\text{max}}$ 、 $P_{\text{grid},\text{min}}$  分别为配网与主网交互功率上下限, 本文中配网无售电功能, 因此下限为 0。

发电机组出力约束为

$$P_{i,\text{mt},\text{min}} \leq P_{i,\text{mt},t} \leq P_{i,\text{mt},\text{max}} \quad (33)$$

$$Q_{i,\text{mt},\text{min}} \leq Q_{i,\text{mt},t} \leq Q_{i,\text{mt},\text{max}} \quad (34)$$

式中:  $P_{i,\text{mt},\text{max}}$ 、 $P_{i,\text{mt},\text{min}}$  分别为发电机组有功出力上下限;  $Q_{i,\text{mt},\text{max}}$ 、 $Q_{i,\text{mt},\text{min}}$  分别为发电机组无功出力上下限。

电储能在时段  $t$  的有功功率  $P_{i,\text{ess},t}$  约束如式(35)所示, 储能荷电状态  $E_{i,\text{ess},t}^{\text{SOC}}$  计算方法如式(36)一式(38)所示。

$$P_{i,\text{ess},\text{min}} \leq P_{i,\text{ess},t} \leq P_{i,\text{ess},\text{max}} \quad (35)$$

$$E_{i,\text{ess},t}^{\text{SOC}} = E_{i,\text{ess},t-1}^{\text{SOC}} - \eta_{i,\text{ess}} P_{i,\text{ess},t} \Delta t / C_{i,\text{ess},\text{max}} \quad (36)$$

$$E_{i,\text{ess},0}^{\text{SOC}} = E_{i,\text{ess},\text{ini}}^{\text{SOC}} \quad (37)$$

$$E_{i,\text{ess},\text{min}}^{\text{SOC}} \leq E_{i,\text{ess},t}^{\text{SOC}} \leq E_{i,\text{ess},\text{max}}^{\text{SOC}} \quad (38)$$

式中:  $P_{i,\text{ess},\text{max}}$ 、 $P_{i,\text{ess},\text{min}}$  分别为节点  $i$  储能的有功功率上下限;  $\Delta t$  为单位时段长度;  $C_{i,\text{ess},\text{max}}$  为电储能的最大容量;  $E_{i,\text{ess},\text{ini}}^{\text{SOC}}$  为电储能初始时段的荷电状态;  $E_{i,\text{ess},\text{max}}^{\text{SOC}}$ 、 $E_{i,\text{ess},\text{min}}^{\text{SOC}}$  分别为节点  $i$  的储能荷电状态上下限, 储能通过电价差的买卖电量获利;  $\eta_{i,\text{ess}}$  如式(39)所示。

$$\eta_{i,\text{ess}} = \begin{cases} \eta_{i,\text{ch}}, & P_{i,\text{ess},t} < 0 \\ \frac{1}{\eta_{i,\text{dis}}}, & P_{i,\text{ess},t} \geq 0 \end{cases} \quad (39)$$

式中,  $\eta_{i, \text{ch}}$ 、 $\eta_{i, \text{dis}}$  分别为充、放电系数。

依据 2.2 节得到区域用户电价响应行为综合模型  $\omega$ , 将其写成等式约束代入到强化学习的训练环境中。响应负荷  $P_{i, \text{adload}, t}$  如式(40)所示, 配网下所有有功负荷值  $P_{\text{load}, t}$  如式(41)所示。

$$P_{i, \text{adload}, t} = F(p_t, \omega) \quad (40)$$

$$P_{\text{load}, t} = \sum_i^I (P_{i, \text{adload}, t} + P_{i, \text{conload}, t}) \quad (41)$$

式中:  $P_{i, \text{adload}, t}$  为经过联邦学习过程的用户综合响应模型预测的响应负荷量;  $F(p_t, \omega)$  为神经网络预测函数, 其中  $\omega$  为区域用户响应模型,  $p_t$  为实时电价;  $P_{i, \text{conload}, t}$  为固定负荷。

配电网发布的实时电价  $p_t$  需遵守相关约束, 限制其为了谋取最大收益而破坏用户的满意度, 如式(42)所示。

$$(p_t - \rho_{\text{grid}, t})^2 \leq C_{\text{pri}} \quad (42)$$

式中,  $C_{\text{pri}}$  为价格参数, 限制批发市场购电单价与实时电价的平方差大小。

综上, 本文所提的数据孤岛下基于联邦学习的用户电价响应刻画及其应用框架的伪代码如下。

**算法:** 数据孤岛下基于联邦学习的用户电价响应刻画及其应用框架

1: Step 1: 输入联邦学习参数

2: 初始化综合模型  $\omega_i$  和最大交互轮次  $l_{\text{max}}$ , 聚合商个数  $N_{\text{LA}}$ , 正则化参数  $\mu$ , 用户模型最大训练次数  $E_{\text{max}}$ , 梯度敏感度  $C$ , 参数学习率  $\eta$

3: Step 2: 获取用户综合响应模型

4: for  $l = 1, 2, \dots, l_{\text{max}}$

5: 配网运营商下发综合模型参数到各聚合商

6: for  $k = 1, 2, \dots, N_{\text{LA}}$

7:  $\omega_{k, l}^E = \omega_i$

8: for  $E = 1, 2, \dots, E_{\text{max}}$

9: 按式(8)一式(10)训练模型

10: 按式(11)更新聚合商模型

11: 按式(12)更新配网运营商模型

12: 输出用户综合响应特性模型  $\omega = \omega_{\text{max}}$

13: Step 3: 基于强化学习的配电网需求响应优化方法

14: 初始化 PPO2 算法中策略网络  $\theta_g$ , 价值网络  $\phi_g$  和智能体最大探索次数  $g_{\text{max}}$

15: for  $g = 1, 2, \dots, g_{\text{max}}$

16: 根据  $\theta_g$  和  $\phi_g$  得到一系列轨迹和估计价值

17: 计算真实奖励和优势函数值

18: 根据式(13)一式(14)更新  $\theta_g$  和  $\phi_g$

19: 转至 Output。

20: Output =  $[\theta_g, \phi_g]$

## 4 算例分析

### 4.1 算例设置

#### 4.1.1 数据设置

本文仿真计算在 python3.7 版本执行, 硬件环

境为 Intel® Core(TM) i7-10700F CPU@2.90 GHz 的处理器, 内存为 16 G, pytorch 版本为 1.8.1, CUDA 版本为 11.1。算例采用修改的 IEEE33 节点为对象, 如图 5 所示。系统配置参数如表 1 和表 2 所示, 其中 LA 的用户模型参数采取随机方式进行生成。而表 3 和表 4 分别展示了联邦学习框架下的参数设置和近端策略优化算法的参数设置。联邦学习神经网络参数和强化学习策略网络参数的设置见附录图 A1。

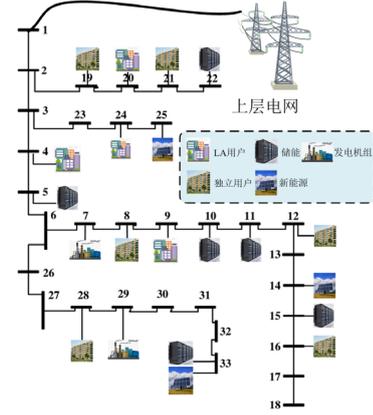


图 5 修改的 IEEE33 节点拓扑图

Fig. 5 Modified IEEE33 node topology

表 1 储能参数

Table 1 ESS parameters

参数	储能编号					
	1	2	3	4	5	6
$\eta_{\text{ch}}$	0.8	0.85	0.75	0.8	0.85	0.75
$\eta_{\text{dis}}$	0.85	0.85	0.83	0.85	0.85	0.83
$C_{\text{ess}, \text{max}}/\text{kWh}$	2000	2000	4000	4000	4000	4000
$E_{\text{ess}, \text{max}}^{\text{SOC}}$	1	1	1	1	1	1
$E_{\text{ess}, \text{min}}^{\text{SOC}}$	0	0	0	0	0	0
$P_{\text{ess}, \text{min}}/\text{kW}$	-400	-400	-800	-800	-800	-800
$P_{\text{ess}, \text{max}}/\text{kW}$	400	400	800	800	800	800

表 2 系统其他参数

Table 2 Other system parameters

参数	数值	参数	数值
$P_{\text{grid}, \text{max}}/\text{kW}$	20 000	$p_{\text{min}}/(\text{元}/\text{kWh})$	0.2
$\Delta t/\text{min}$	30	$p_{\text{max}}/(\text{元}/\text{kWh})$	1.5

表 3 联邦学习框架参数设置

Table 3 Parameter setting of federated learning framework

参数	设定数值
交互轮次	30
本地训练轮次	20
正则项参数 $\mu$	8
噪声乘子 $z$	0.1
梯度敏感度 $C$	2

表 4 近端策略优化算法参数设置

Table 4 Parameter setting of proximal policy optimization

参数	设定数值
训练迭代次数	1000
神经网络学习率	0.001
奖励折扣率	0.9

同时, 考虑到在实际应用中, 独立用户的响应数据难以获取。因此借鉴文献[30-31]的思想, 根据获取试点聚合商的历史数据分布, 量化独立用户响应模型的参数估计。用置信区间表征独立用户的参数区间, 置信度越高表示独立用户的参数落入分布的概率越大, 置信区间也越宽, 见附录 B。

本文采用了国内南方某省市 2021—2023 年工商业电价作为本文负荷聚合商的代理电价<sup>[32]</sup>, 共 2000 个采样点, 见附录图 A2。随机生成不同聚合商模型参数, 并根据式(3)分别生成 900、1500、2000 和 1200 个“代理电价-响应功率”数据。对 4 个 LA 用户的响应情况进行统计, 并以功率数据箱形图展示不同 LA 的数据分布情况, 如图 6 所示。可见, 各 LA 在同样的价格区间存在明显的功率数据分布差异, 其中 LA1 与 LA3 数据位于总体功率数据的两侧, 分布差异最大。

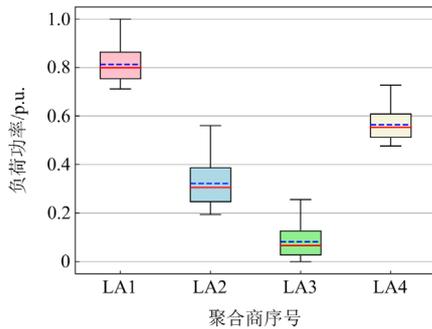


图 6 LA 用户模型的数据集箱形图

Fig. 6 Box plot of the LA user models' data set

#### 4.1.2 案例设置

为验证本文所提数据孤岛下基于联邦学习的用户电价响应刻画方法的有效性及其在配网优化运行中应用的可行性, 此处设计 2 个仿真案例进行分析说明, 概述如下。

1) 联邦学习下用户响应行为刻画精度分析。通过将所提差分隐私-联邦近端学习算法与其他算法对比, 分析明确本文算法在保障区域用户响应行为刻画的有效性。

2) 用户响应行为刻画在配网运行中的应用分析。通过对比不同场景下应用用户行为刻画模型的配网优化运行结果, 证明本文所提应用方法对提升

配网运行收益具有实用性。

#### 4.1.3 评价指标

为了评估用户响应行为应用的实用性, 可直接使用上述配网运行相关收益为评价指标。而对于衡量用户响应行为刻画模型的精度, 本文采用准确率 (accuracy, ACC) 来计算模型的拟合效果。 $A_{cc}$  越大代表模型拟合效果越好, 且为了防止数据太小导致敏感度增大, 设置了分段函数, 如式(43)所示。

$$A_{cc} = \begin{cases} 1 - 1/N \sum_{i=1}^N \text{abs}\left(\frac{y_{\text{True},i} - y_{\text{Pred},i}}{y_{\text{True},i}}\right), & |y_{\text{True},i}| > \rho \\ 1 - 2/N \sum_{i=1}^N \text{abs}\left(\frac{y_{\text{True},i} - y_{\text{Pred},i}}{y_{\text{True},i} + y_{\text{Pred},i}}\right), & |y_{\text{True},i}| \leq \rho \end{cases} \quad (43)$$

式中:  $N$  为样本量;  $\text{abs}(\cdot)$  为绝对值函数;  $y_{\text{True},i}$  为第  $i$  个样本的负荷实际值;  $y_{\text{Pred},i}$  为第  $i$  个样本的负荷预测值;  $\rho$  为分段函数参数, 取 0.05。

#### 4.2 联邦学习下用户响应行为刻画精度分析

为评估本文所提的差分隐私-联邦近端学习算法在区域用户响应刻画方面的优势, 设置以下 3 种算法进行对比实验。

1) Allin: 集中训练数据集, 训练条件与其他算法相同, 但不具备用户数据隐私保护。

2) FedAvg: 传统联邦算法, 分布式训练数据, 训练条件与其他算法一致, 具备一定隐私保护。

3) FedProx: 联邦近端学习算法, 分布式训练数据且能处理数据之间的分布差距。

本文考虑了用户数据集分布不均匀情况, 根据文献[22], 采用不平衡率划分单个数据集的分布, 以此验证算法在分布不均匀的数据中能够学习到有用信息。将大数据集按照中位数划分为两个子集, 分别是种子数据集 0 与种子数据集 1。定义不平衡率  $I_B \in (0.5, 1)$ , 从种子数据集 0 中抽取数量占比为  $I_B$  的实例, 数据集 1 抽取占比为  $1 - I_B$  的实例, 构成数据集。平衡划分即定义  $I_B = 0.5$  构成的数据集。定义训练集和测试集占比为 4:1。

首先探讨  $I_B = 0.5$  的数据集下算法的拟合度, 这时由于单个数据集分布较为平均, 算法的精度主要受到了 4 个数据集间分布差异的影响。迭代情况如图 7 所示。

需要指出, loss 为训练数据的平方损失值, 其变化情况不等同于测试集准确率变化情况。Allin 算法为集中训练方式, 需利用所有聚合商的数据训练模型。为使算法模型训练次数相同, 图中 Allin 算法的 1 次迭代结果表示该算法迭代了 20 次。从图 7 可以看出, 大约进行 10 次迭代, 测试集准确率趋于稳定, Allin 集中训练数据的准确率最高, 但是这种

训练方式侵犯了用户隐私权。本文算法的准确率位于 FedProx 和 FedAvg 之间，由于加入差分隐私，对原有算法添加部分扰动导致准确率降低。可以理解的是，算法在处理数据集间分布差异时，FedProx 起到了很好的效果，而本文算法既增强了模型交互的数据安全性，同时其准确率高 FedAvg 算法，表明本文所提算法是合理的。

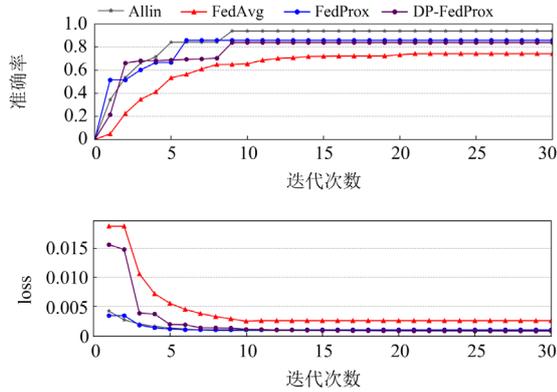


图 7 算法迭代时准确率和 loss 值

Fig. 7 Accuracy and loss value of the algorithm iteration

为观察在不同数据集中不平衡率  $I_B$  对 4 种算法的影响程度，取不同平衡率下实验的准确率，如图 8 所示。

首先从各数据集中可以观察到，随着不平衡率  $I_B$  的增大，算法的准确率逐渐降低，这是由于不平

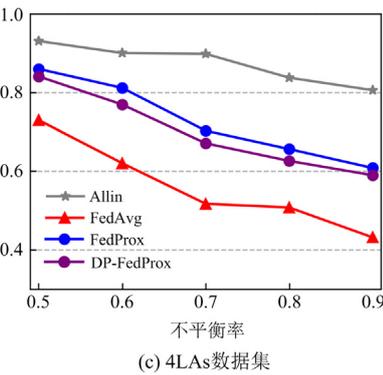
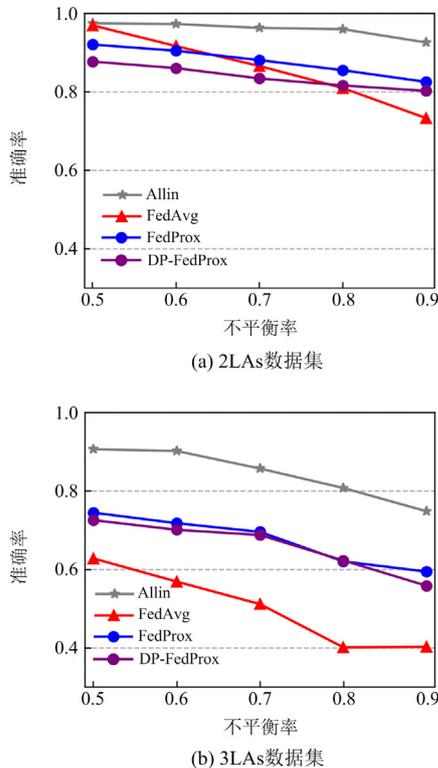


图 8 多个不平衡率下的准确率

Fig. 8 Accuracy with different data's imbalance

衡率加大了各数据集的分布差异，算法难以均衡训练数据。并且在大部分情况下，FedAvg 算法的拟合强度都弱于 Allin、FedProx 和 DP-FedProx 算法，这跟图 7 的结论近乎一致。不平衡率对 FedAvg 的不利影响也最明显， $I_B$  越大其模型性能越差。对比 FedAvg，由于联邦近端算法增加了正则项和非准确解定义，能够抑制聚合商模型的过拟合，使得网络模型训练和与综合模型的网络差异达到有效平衡，因此本文所提算法在一定程度上提高了数据的拟合强度。

进一步观察到参与的聚合商数量不同对算法也有影响，一般来说参与数量越大会导致数据集分布差异增大，例如本文算例中，从两个参与者到三个参与者参与，本文所提算法的准确率大部分降低。然而第 4 个负荷聚合商的参与使得算法准确率提升。从图 6 可以发现，LA4 的数据集位于中间，在同样的电价区间中，算法目标是为了找到均衡点以最小化损失。可以说明 LA4 的数据集更靠近均衡点，相对于 3 个聚合商参与，LA4 的加入能够使得算法的准确率增大。这表明参与者数量对算法的准确率也产生了一定影响。同时，这也展示了所提方法的鲁棒性，在面临不同情况下都并没因引入了差分隐私机制而造成准确率大幅降低。

在传输数据量上，传统方案只需传输负荷聚合商的“代理电价-响应功率”数据，数据量为特征数量(2)×数据数量(900+1500+2000+1200)×浮点数(8)；而联邦学习方案的传输数据量大小为用户数量(4)×模型参数量(12+12×4+4×4+4)×交互轮次(30)×浮点数(8)。

另外，从表 5 中可以发现，Allin 算法的准确率始终较高，一方面因为集中式学习与分布式学习的模型更新方式具有很大的差异，体现在集中式学习训练属于串行训练，而联邦学习训练为并行。不同于串行训练，部分更新信息的丢失并不会中断并行

训练过程, 这可能导致所得模型性能不佳。另一方面因为数据集较为单一, 文献[33-34]对联邦学习进行调优比较, 结果也显示出集中式学习在大部分数据集下拟合效果处于较优。然而, 本文提出的 DP-FedProx 算法相对于集中式学习能够保护数据隐私、减少通信开销, 具有更大的应用前景。相对于传统联邦学习, 其收敛速度更快, 训练效果更优, 如表 5 所示。

表 5 本文方案与传统方案的综合对比

Table 5 Comprehensive comparison between proposed scheme and traditional scheme

方案	隐私保护程度	训练效果/%		训练时间/min	模型个数/个	数据传输量/bit
		中位	最差			
集中式	差	87.5	73.2	15.1	1	$8.96 \times 10^4$
传统联邦	好	47.8	40.1	6.7	4	$7.68 \times 10^4$
本文	最好	67.9	57.6	5.2	4	$7.68 \times 10^4$

### 4.3 用户响应行为刻画在配网运行中的应用分析

4 个负荷聚合商参与由 DSO 主导的联邦学习过程, 学习完成后, DSO 得到综合用户行为刻画模型。将综合模型嵌入到强化学习环境, 利用 PPO2 算法优化配电网实时电价与储能出力, 探究用户响应行为刻画在配网运行优化中的应用意义。

考虑到实际应用中独立用户与参与综合模型构建的聚合商用户普遍存在差异, 独立用户响应特性见附录图 B1。文章设立 4 个场景展开分析来证明所提方法的实用性, 其中不同置信度表示用户间差异情况(见附录表 B1):

场景一: DSO 不制定实时电价, 但通过配置储能和发电机组出力获取收益;

场景二: 在所得综合模型下, 设定独立用户响应模型参数的置信度为 30%;

场景三: 独立用户响应模型参数置信度为 60%;

场景四: 独立用户响应模型参数置信度为 90%。

本文采用 MILP 模型求解场景一问题, 获取全局最优解。

表 6 为不同场景下的电网收益, 可以看出, 实时电价的制定不仅增加了 DSO 的收益来源, 并且可以有效降低负荷峰谷差, 即使是最差的场景中, 其峰谷差相对减少了 4.46%。通过对独立负荷的应用

表 6 不同场景下的电网收益

Table 6 Benefits of power grid in different scenarios

场景	负荷收益/元	储能收益/元	峰谷差/kW
一	0	4323	8854
二	5308	4596	8459
三	5096	4596	8443
四	4936	4596	8353

分析, 可见在不同置信度的设置下, 用户负荷对实时电价的响应功率大小不一, 但本文方法所得结果都可对用户进行有效指导, 这说明本文所提框架下模型具有实用性。同时, 随着独立用户模型参数置信度的提高, 所得策略仍然确保了配电网的收益。

图 9 为不同场景下储能状态的时序变化。DSO 每半小时更新实时电价, 对储能的利用更加充分, 充放电的操作更加频繁, 在第 16 个时段下场景一储能处于满荷状态; 而其余场景储能在进行放电, 第 20 个时段才充至满荷。最终储能收益提高了 6.3%。

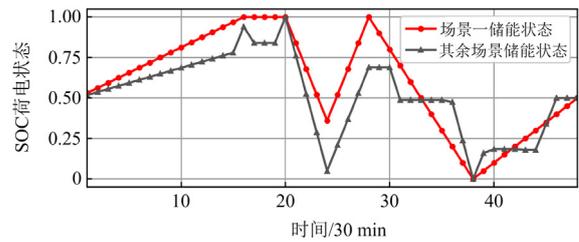


图 9 储能荷电状态分析

Fig. 9 Analysis state of charge of energy storage

最后, 为说明近端策略优化方法的有效性, 将不同强化学习算法的收敛性进行比较, 分别引入了策略梯度算法(policy gradient, PG)和深度 Q 学习算法(deep Q network, DQN)。从图 10 看出, 针对本文提出的配电网电价型需求响应运行优化模型, PPO2 算法表现出更强的收敛性, 所得奖励值也越高。

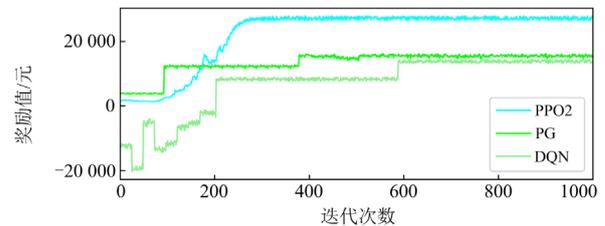


图 10 算法迭代奖励值

Fig. 10 Algorithm iteration reward value

## 5 结论

为解决现阶段用户数据隐私需求和配网需求响应相互冲突的问题, 文章设计了数据孤岛下基于差分隐私-联邦近端算法的用户行为响应刻画方法, 并构建了改进的策略近端优化算法, 将用户行为刻画模型应用于配网优化运行。经过算例验证, 可总结所提方法框架的特点如下。

1) 有效地权衡用户隐私保护和行为刻画精度。所提基于差分隐私-联邦近端算法的用户行为响应刻画方法, 在聚合商本地模型的训练方面通过差分隐私机制的引入避免了参数共享时的隐私风险, 同

时利用模型距离的惩罚项引导本地模型学习,以克服数据间的分布差异造成收敛困难的问题。算例结果表明,所得的综合模型能够在保护情况下保持对用户响应行为准确地刻画。

2) 在配网运行优化应用中具有实用性。基于改进策略近端优化算法,将用户响应行为综合模型以独立用户的行为约束形式纳入电价型需求响应的配网运行优化中。算例表明,在考虑多个不同置信度的独立用户响应模型参数时,所提方法都可有效提升配网运行的收益。

此外,需明确指出的是,本文尚未对聚合商参与联邦学习的动力进行细化分析,如何构建其收益模型,通过经济激励吸引更多的聚合商参与到联邦学习框架中是值得讨论的课题。同时,对用户响应行为刻画模型的应用方面采用的是强化学习的非解析方法,其最优性难以得到保障,如何将响应行为模型进行知识显式解析以提高应用决策的有效性、对其进一步推广具有重要意义。

附录 A

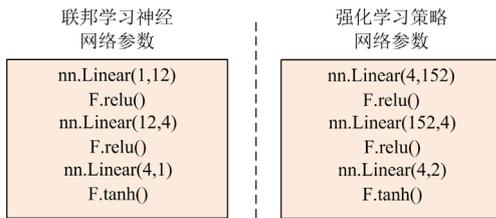


图 A1 联邦学习神经网络参数和强化学习策略网络参数

Fig. A1 Parameters of FL neural network and RL policy network in this paper

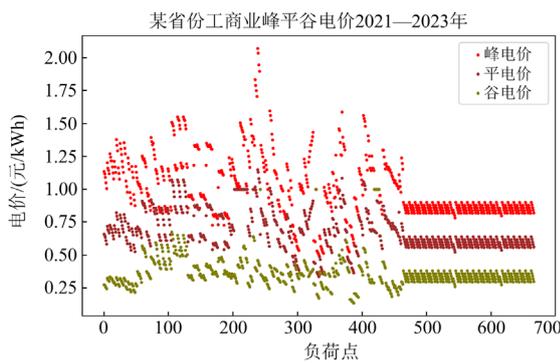


图 A2 国内某省份工商业代理电价数据集

Fig. A2 Domestic provincial industrial and commercial agent electricity price dataset

附录 B

从文献[23-24]推导可知,在适当的区域内,用户用电功率与本身的参数  $\beta$  呈反比关系,而与用电

价格成正比。假定  $\beta$  呈高斯分布,模拟 100 个试点聚合商的响应运行情况,参数分布如式(B1)所示。

$$\beta \sim N(-0.018, 0.0107^2) \quad (B1)$$

为了更好地了解参数和价格对聚合商负荷的影响,消除负荷平均水平差异,借鉴于标准化思想,定义了负荷削减率  $\eta$ ,如式(B2)所示。

$$\eta = \frac{P_{load,max} - P_{load,t}}{P_{load,max}} \quad (B2)$$

式中:  $P_{load,max}$  为负荷功率最大值;  $P_{load,t}$  为时段  $t$  的负荷功率。

绘制价差-参数  $\beta$ -负荷削减率三维图,如图 B1 所示,其中价差是为了使  $x$  坐标从 0 开始,意思为用电价格减去最小用电价格。

在正态分布中,每一个置信度对应一个置信区间,置信区间就是变量的区间估计,且置信度越高,其置信区间越宽,样本估计值分布广。置信区间表示为  $[\mu - z\sigma, \mu + z\sigma]$ ,  $z$  根据置信度查表可得。

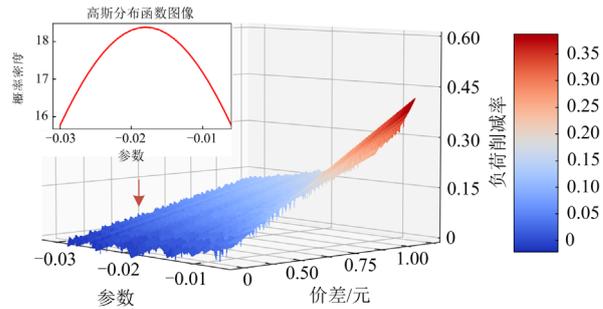


图 B1 独立用户响应特性建模

Fig. B1 Modeling individual user response characteristics

表 B1 3 种场景下独立用户参数  $\beta$  取值

Table B1 Values of individual user parameters  $\beta$  in three scenarios

用户	场景二	场景三	场景四
1	-0.017 89	-0.016 97	-0.006 82
2	-0.018 08	-0.020 10	-0.007 01
3	-0.018 15	-0.017 33	-0.023 15
4	-0.017 68	-0.013 09	-0.020 84
5	-0.018 12	-0.019 09	-0.019 92
6	-0.017 51	-0.018 64	-0.016 84

参考文献

[1] 代贤忠, 韩新阳, 靳晓凌. 需求响应参与电力平衡的成本效益评估方法[J]. 中国电力, 2022, 55(10): 170-177.  
DAI Xianzhong, HAN Xinyang, JIN Xiaoling. cost-benefit assessment method for demand response participating in power balance[J]. Electric Power, 2022, 55(10): 170-177.

[2] 李彬, 郝一浩, 明雨, 等. 基于时间窗口的需求响应信息交换汇聚流量优化机制[J]. 供用电, 2023, 40(6): 84-90.  
LI Bin, HAO Yihao, MING Yu, et al. Optimization mechanism of convergence flow based on time window

- in demand response information exchange system[J]. *Distribution & Utilization*, 2023, 40(6): 84-90.
- [3] 余子淳, 范宏, 夏世威. 计及电动公交车 V2G 响应的区域综合能源系统两阶段优化调度[J]. *中国电力*, 2022, 55(7): 179-192.  
YU Zichun, FAN Hong, XIA Shiwei. Two-stage optimal scheduling of regional integrated energy system considering V2G response of electric buses[J]. *Electric Power*, 2022, 55(7): 179-192.
- [4] CHEN X, YU T, PAN Z, et al. Graph representation learning-based residential electricity behavior identification and energy management[J]. *Protection and Control of Modern Power Systems*, 2023, 8(1): 34-50.
- [5] FU X, WU X, ZHANG C, et al. Planning of distributed renewable energy systems under uncertainty based on statistical machine learning[J]. *Protection and Control of Modern Power Systems*, 2022, 7(1): 50-65.
- [6] 秦文萍, 杨镜司, 景祥, 等. 计及需求响应的微电网综合能源多时空尺度优化调度[J]. *上海交通大学学报*, 2023, 57(12): 1583-1596.  
QIN Wenping, YANG Jingsi, JING Xiang, et al. Multi-time-space scale optimal dispatch of integrated energy in micro-energy grid considering demand response[J]. *Journal of Shanghai Jiaotong University*, 2023, 57(12): 1583-1596.
- [7] 罗伟民, 孙钦, 周蔚南, 等. 计及峰谷分时电价与需求响应的互联网数据中心储能经济性分析[J]. *供用电*, 2022, 39(7): 40-45.  
LUO Weimin, SUN Qin, ZHOU Weinan, et al. Economic analysis of IDC with energy storage system considering peak valley time-of-use price[J]. *Distribution & Utilization*, 2022, 39(7): 40-45.
- [8] MENG S, AMELIN M. Estimating the price elasticity of residential power demand using a bottom-up approach[C] // 2016 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), October 25-28, 2016, Xi'an, China: 243-247.
- [9] RUAN J, LIU G, QIU J, et al. Time-varying price elasticity of demand estimation for demand-side smart dynamic pricing[J]. *Applied Energy*, 2022, 322: 101-119.
- [10] 李孟阳, 李国杰, 汪可友, 等. 考虑需求响应及调频性能变化的虚拟电厂日前投标策略[J]. *电力系统保护与控制*, 2023, 51(3): 13-25.  
LI Mengyang, LI Guojie, WANG Keyou, et al. Day-ahead bidding strategy for virtual power plant considering demand response and frequency regulation performance variation[J]. *Power System Protection and Control*, 2023, 51(3): 13-25.
- [11] 闫梦阳, 李华强, 王俊翔, 等. 计及综合需求响应不确定性的园区综合能源系统优化运行模型[J]. *电力系统保护与控制*, 2022, 50(2): 163-175.  
YAN Mengyang, LI Huaqiang, WANG Junxiang, et al. Optimal operation model of a park integrated energy system considering uncertainty of integrated demand response[J]. *Power System Protection and Control*, 2022, 50(2): 163-175.
- [12] 阮嘉祺, 柳文轩, 赵俊华, 等. 面向需求响应的数据驱动零售电价定价策略[J]. *电力系统自动化*, 2023, 47(7): 133-141.  
RUAN Jiaqi, LIU Wenxuan, ZHAO Junhua, et al. Data-driven electricity retail pricing strategy for demand response[J]. *Automation of Electric Power Systems*, 2023, 47(7): 133-141.
- [13] 傅质馨, 李紫嫣, 李寒兵, 等. 基于分时电价和激励补贴机制的家庭能量双层优化模型[J]. *电力建设*, 2021, 42(11): 108-116.  
FU Zhixin, LI Ziyang, LI Hanbing, et al. Two-tier optimization model of home energy considering time-of-use electricity price and incentive subsidy mechanism[J]. *Electric Power Construction*, 2021, 42(11): 108-116.
- [14] 任惠, 陆海涛, 卢锦玲, 等. 考虑信息物理系统耦合和用户响应差异的负荷聚合商需求响应特性分析[J]. *电网技术*, 2020, 44(10): 3927-3936.  
REN Hui, LU Haitao, LU Jinling, et al. Analysis of LA demand response characteristics considering cyber physical system coupling and user's response difference[J]. *Power System Technology*, 2020, 44(10): 3927-3936.
- [15] MOHAMMAD N, RAHMAN A U, NANDY A. Optimization of thermostatically controlled appliances to minimize energy consumption cost based on real-time pricing[C] // 2021 2nd International Conference for Emerging Technology (INCET), May 21-23, 2021, Belagavi, India: 1-4.
- [16] 陈明昊, 孙毅, 胡亚杰, 等. 基于纵向联邦强化学习的居民社区综合能源系统协同训练与优化管理方法[J]. *中国电机工程学报*, 2022, 42(15): 5535-5550.  
CHEN Minghao, SUN Yi, HU Yajie, et al. The collaborative training and management-optimized method for residential integrated energy system based on vertical federated reinforcement learning[J]. *Proceedings of the CSEE*, 2022, 42(15): 5535-5550.
- [17] 龚诚嘉锐, 林顺富, 边晓燕, 等. 基于多主体主从博弈的负荷聚合商经济优化模型[J]. *电力系统保护与控制*, 2022, 50(2): 30-40.  
GONG Chengjiarui, LIN Shunfu, BIAN Xiaoyan, et al. Economic optimization model of a load aggregator based on the multi-agent Stackelberg game[J]. *Power System Protection and Control*, 2022, 50(2): 30-40.
- [18] 刘子旭, 米阳, 卢长坤, 等. 计及需求响应和风力发电消纳的电-热系统低碳优化调度[J]. *上海交通大学学报*, 2023, 57(7): 835-844.  
LIU Zixu, MI Yang, LU Changkun, et al. Low-carbon optimal dispatch of electric-thermal system considering demand response and wind power consumption[J]. *Journal of Shanghai Jiaotong University*, 2023, 57(7): 835-844.

- [19] 陈钱蓁, 高红均, 王晓辉, 等. 面向产消用户的售电公司发-用电多元电力套餐优化[J]. 电力自动化设备, 2023, 43(5): 154-162.  
CHEN Qianzhen, GAO Hongjun, WANG Xiaohui, et al. Prosumer oriented multiple generation-consumption electricity package optimization for electricity retailers[J]. Electric Power Automation Equipment, 2023, 43(5): 154-162.
- [20] EKSIN C, DELIC H, RIBEIRO A. Demand response management in smart grids with heterogeneous consumer preferences[J]. IEEE Transactions on Smart Grid, 2015, 6: 3082-3094.
- [21] 郭方洪, 刘师硕, 吴祥, 等. 基于联邦学习的含不平衡样本数据电力变压器故障诊断[J]. 电力系统自动化, 2023, 47(10): 145-152.  
GUO Fanghong, LIU Shishuo, WU Xiang, et al. Federated learning based fault diagnosis of power transformer with unbalanced sample data[J]. Automation of Electric Power Systems, 2023, 47(10): 145-152.
- [22] 王蓓蓓, 朱竟, 王嘉乐, 等. 电表数据隐私保护下的行业电力负荷联邦学习预测框架[J]. 电力系统自动化, 2023, 47(13): 86-93.  
WANG Beibei, ZHU Jing, WANG Jiale, et al. Federated-learning based industry load forecasting framework under privacy protection of meter data[J]. Automation of Electric Power Systems, 2023, 47(13): 86-93.
- [23] 田家会, 吕锡香, 邹仁朋, 等. 一种联邦学习中的公平资源分配方案[J]. 计算机研究与发展, 2022, 59(6): 1240-1254.  
TIAN Jiahui, LÜ Xixiang, ZOU Renpeng, et al. A fair resource allocation scheme in federated learning[J]. Computer Research and Development, 2022, 59(6): 1240-1254.
- [24] 李彦君, 裴玮, 肖浩, 等. 基于深度学习的微网需求响应特性封装与配电网优化运行[J]. 电力系统自动化, 2021, 45(10): 157-165.  
LI Yanjun, PEI Wei, XIAO Hao, et al. Deep learning based characteristic packaging of demand response for microgrids and optimal operation of distribution network[J]. Automation of Electric Power Systems, 2021, 45(10): 157-165.
- [25] LI T, SAHU A K, ZAHEER M, et al. Federated optimization in heterogeneous networks[J]. Proceedings of Machine Learning and Systems, 2020, 2: 429-450.
- [26] 黄健, 侯健生, 季克勤, 等. 基于电热氢混合储能的综合能源系统的能量管理优化研究[J]. 电工电能新技术, 2022, 41(12): 9-19.  
HUANG Jian, HOU Jiansheng, JI Keqin, et al. Research on energy management optimization of integrated energy system based on electric-thermal-hydrogen hybrid energy storage[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(12): 9-19.
- [27] 刘子祺, 苏婷婷, 何佳阳, 等. 基于多目标粒子群算法的配电网储能优化配置研究[J]. 综合智慧能源, 2023, 45(6): 9-16.  
LIU Ziqi, SU Tingting, HE Jiayang, et al. Research on the optimal allocation of energy storage in distribution network based on multi-objective particle swarm optimization algorithm[J]. Integrated Intelligent Energy, 2023, 45(6): 9-16.
- [28] ZHANG J, ZHANG Z, HAN S, et al. Proximal policy optimization via enhanced exploration efficiency[J]. Information Sciences, 2022, 609: 750-765.
- [29] HA T, DANG T K, DANG T T, et al. Differential privacy in deep learning: an overview[C] // 2019 International Conference on Advanced Computing and Applications (ACOMP), November 26-28, 2019, Nha Trang, Vietnam: 102-114.
- [30] SHARMA I, BHATTACHARYA K, CANIZARES C. Smart distribution system operations with price-responsive and controllable loads[J]. IEEE Transactions on Smart Grid, 2015, 6(2): 1-10.
- [31] GIANNELLOS S, KONSTANTELOS I, STRBAC G. Option value of demand-side response schemes under decision-dependent uncertainty[J]. IEEE Transactions on Power Systems, 2019, 33(5): 5103-5113.
- [32] WANG C, GAO R, QIU F, et al. Risk-based distributionally robust optimal power flow with dynamic line rating[J]. IEEE Transactions on Power Systems, 2018, 33(6): 6074-6086.
- [33] PAN W, ZHOU H. Fairness and effectiveness in federated learning on non-independent and identically distributed data[C] // 2023 IEEE 3rd International Conference on Computer Communication and Artificial Intelligence (CCAI), May 26-28, 2023, Taiyuan, China: 97-102.
- [34] ZONG R, QIN Y, WU F, et al. Fedcs: efficient communication scheduling in decentralized federated learning[J]. Information Fusion, 2023, 102: 1566-1572.

收稿日期: 2023-08-06; 修回日期: 2023-11-14

作者简介:

李锦辉(1999—), 男, 硕士研究生, 研究方向为需求响应技术应用、人工智能在电力系统中的应用; E-mail: jinhuili6423@126.com

吴毓峰(1998—), 男, 博士研究生, 研究方向为人工智能在电力系统中的应用、电力系统优化运行与控制; E-mail: wuyuffeng@163.com

余涛(1974—), 男, 通信作者, 博士, 教授, 主要研究方向为复杂电力系统的非线性控制理论和仿真。E-mail: taoyu1@scut.edu.cn

(编辑 张颖)