

DOI: 10.19783/j.cnki.pspc.250113

# 考虑数据隐私保护的分布式电源集群自适应 可信协同决策方法

崔婧琪<sup>1</sup>, 冀浩然<sup>1</sup>, 李鹏<sup>1</sup>, 喻磊<sup>2</sup>, 段舒尹<sup>2</sup>, 雷一勇<sup>3</sup>

(1. 智能配用电装备与系统全国重点实验室(天津大学), 天津 300072; 2. 南方电网科学研究院有限责任公司, 广东 广州 510663; 3. 中国南方电网有限责任公司, 广东 广州 510663)

**摘要:** 规模化分布式电源的快速波动, 容易导致配电网电压越限、波动剧烈等一系列问题, 进而影响配电网安全稳定运行。此外, 配电网各集群可能归属于不同利益主体, 集群间隐私保护需求也日趋重要。针对多利益主体参与下配电网分布式电源集群控制的问题, 提出了一种考虑数据隐私保护的分布式电源集群自适应可信协同决策方法。首先, 基于拆分联邦学习方法构建配电网多集群可信协同框架, 并建立面向配电网电压决策的深度学习模型, 在考虑配电网利益主体间隐私保护的前提下实现了多集群之间的数据融合与协同。然后, 在深度学习模型中增添奖励机制对量测数据进行优劣识别, 实现了深度学习模型的自适应更新功能。最后, 在广州蕉门算例上验证了所提方法的可行性与有效性。结果表明, 所提方法具有较强的隐私保护性能, 并且能提高配电网的电压质量, 有效解决了配电网的电压越限问题。

**关键词:** 配电网; 集群控制; 分布式电源; 自适应控制; 隐私保护

## Adaptive and trustworthy collaborative decision-making for distributed generator clusters considering data privacy protection

CUI Jingqi<sup>1</sup>, JI Haoran<sup>1</sup>, LI Peng<sup>1</sup>, YU Lei<sup>2</sup>, DUAN Shuyin<sup>2</sup>, LEI Yiyong<sup>3</sup>

(1. State Key Laboratory of Intelligent Power Distribution Equipment and System, Tianjin University, Tianjin 300072, China;  
2. China Southern Power Grid Electric Power Research Institute Co., Ltd., Guangzhou 510663, China;  
3. China Southern Power Grid Company Limited, Guangzhou 510663, China)

**Abstract:** Rapid fluctuations of large-scale distributed generation (DG) can easily cause issues such as voltage violation in distribution networks, affecting their safe and stable operation. Additionally, distribution clusters may belong to different stakeholders, making inter-cluster data privacy increasingly important. To address the problem of DG cluster control under multiple stakeholders, an adaptive and trustworthy collaborative decision-making method that considers data privacy protection is proposed. First, a multi-cluster trusted collaborative framework for distribution networks is constructed based on split federated learning approach, and a deep learning model is established for voltage decision-making. This framework enables data fusion and collaboration among multiple clusters with privacy protection between stakeholders. Then, a reward mechanism is incorporated into the deep learning model to evaluate the quality of measurement data, allowing for adaptive model updates. Finally, the feasibility and effectiveness of the proposed method are verified using a case study of the Jiaomen distribution network in Guangzhou. The results demonstrate that the proposed method offers strong privacy protection capabilities, improves voltage quality, and effectively mitigates voltage violation issues in the distribution network.

This work is supported by the National Natural Science Foundation of China (No. U22B20114).

**Key words:** distribution network; cluster control; distributed generation; adaptive control; privacy protection

基金项目: 国家自然科学基金项目资助(U22B20114); 南方电网公司科技项目资助(ZBKJXM20232291)

## 0 引言

分布式电源(distributed generator, DG)大规模不均匀接入配电网,使得配电网的运行与控制面临巨大挑战。DG 出力具有不确定性强的特点,容易引发配电网电压越限等问题<sup>[1-4]</sup>。传统配电网电压调节设备主要有有载调压变压器和静止无功补偿器等<sup>[5]</sup>,调节速度慢,往往难以适应配电网 DG 出力波动快的场景。而利用 DG 换流器剩余容量为配电网提供无功支撑,以响应源荷的快速波动,能够有效提升电压质量,并逐渐成为一项研究热点<sup>[6]</sup>。

目前,配电网 DG 无功控制方法主要分为集中式控制和分布式集群控制两类<sup>[7]</sup>。传统集中式 DG 无功控制方法通过集中整合配电网所有数据,基于全局数据对配电网进行控制决策,能够实现全局最优。文献[8]提出了一种基于模型降维等值模型的配电网分层协调无功优化方法,降低了配电网优化计算规模,实现了无功优化数学模型与数据驱动模型的深度结合;文献[9]提出了一种用于发电主导型的电压控制方法,描述了电网中功率损耗的来源,最大限度地提高了网络的有功功率出力;文献[10]针对 DG 的接入加剧配电网电压越限的问题,提出了一种数据驱动的电压控制方法,在多个时间尺度上协调 DG 逆变器和有载调压变压器。相较于传统集中式控制,分布式集群控制作为一种新型控制架构,受到国内外学者广泛关注。文献[11]以各集群自身收益最大为目标,提出了一种基于分布式的配电网双层联合优化调度方法;文献[12]为缓解海量信息涌现下配电网集中计算压力,提出了一种基于深度强化学习的就地电压控制方法,实现了电压就地快速调节;文献[13]提出了一种基于反事实多智能体策略梯度算法的电压协同方法,实现了配电网有功和无功的联合快速控制。以上研究致力于平抑 DG 快速不确定性波动,验证了分布式集群电压控制的可行性与高效性。

然而,随着多利益主体的加入,不同集群可能归属于不同主体,多集群数据隐私保护需求愈发迫切<sup>[14]</sup>。隐私保护的挑战是在确保数据隐私安全的情况下打破各个利益主体的“数据孤岛”,在保护隐私的基础上实现数据融合。在计算机与通信领域,隐私计算技术快速发展,其中以联邦学习(federated learning, FL)为代表的基于机器学习的隐私保护框架成熟度高,得到了广泛的研究与应用。

FL 在 2017 年由谷歌公司提出后,吸引了众多领域学者的关注,在电力系统数据安全领域也有显著进展。文献[15]提出了一种考虑多利益主体隐私

保护需求的云边协同电压控制,运用 FL 框架实现对多利益主体敏感调度数据的保护;文献[16]提出了一种基于联邦强化学习的多智能体分布式协同优化方法,该方法只利用各个智能体的局部信息便可实现全局优化;文献[17]提出一种个性化联邦学习方法,用于消费者的负荷预测,该方法不仅充分保护了消费者的隐私数据,而且提高了预测精度;文献[18]针对用户数据的隐私需求和电网优化调度相冲突的问题,提出一种基于联邦学习的用户电价响应行为刻画方法,该方法在保障用户隐私的前提下,提高了配电网的综合效益;文献[19]提出一种基于自适应联邦学习的输配网-静态综合状态估计的方法,在保护电力系统数据隐私的前提下,实现了系统的状态快速感知,并且验证了该方法能够提高状态估计的准确率。文献[20]提出了一种用于设备端非侵入式负荷识别的轻量级联邦学习方法,促进了电力需求识别和电力行为感知,实现了需求侧的能源管理,并且在实际数据集上的实例研究验证了该方法在精度和效率方面优于传统方法。

FL 将整个模型放在了边缘侧训练,存在的不足是每个边缘计算装置必须完成完整的深度学习模型训练,但边缘计算装置的计算资源受限,不利于大规模数据的训练。拆分联邦学习<sup>[21]</sup>(splitfed learning, SFL)将大体量网络模型放到了云端训练,相比于 FL 降低了对边缘计算装置的算力要求,是一种新兴的分布式机器学习方法。在现有研究中,文献[22]建立了基于 SFL 的云-边-端边缘智能框架,在计算资源有限的智能电表上实现模型协同训练,进行负荷预测,并证明了所提方法能减小内存占用并具有良好的预测精度。

本文应用 SFL 框架,提出了一种考虑数据隐私保护的 DG 集群可信协同运行控制方法。配电网各个边缘侧利用集群内运行数据进行分布式拆分训练,云侧基于联邦学习整合多个边缘侧的数据并进行集群间数据协同,增加了集群之间的协调与联系,实现了多集群协同控制功能。同时,为了优化深度学习模型拟合的电压控制策略,在模型中加入自适应奖励机制对量测数据进行优劣识别,提高了配电网电压控制的效果,实现了模型自适应更新功能。

## 1 基于 SFL 的配电网多集群可信协同框架

为充分考虑配电网多集群之间、云-边之间隐私保护需求,拟基于 SFL 构建配电网多集群可信协同框架,如图 1 所示。其中,整体架构可以划分为规模化源荷接入下的配电网集群、边缘计算装置、云端服务器 3 个层次。

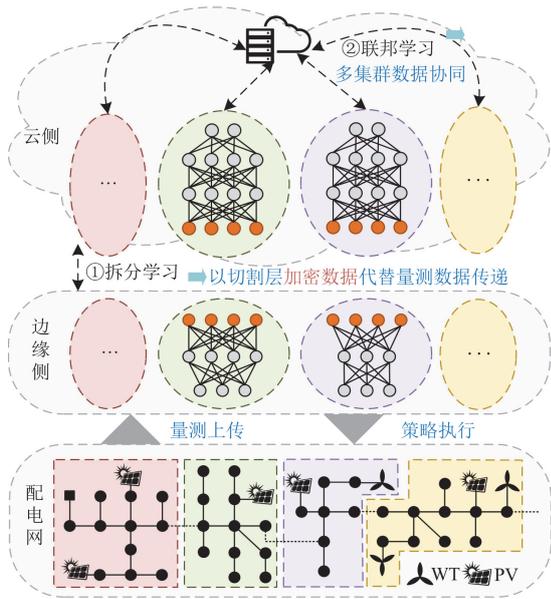


图1 基于SFL的配电网多集群可信协同框架

Fig. 1 A multi-cluster trusted cooperation framework for distribution networks based on SFL

在配电网侧, 规模化源荷接入下配电网被分为多个集群, 各集群采集网络节点信息并将其上传到边缘侧对应的边缘计算装置中, 进行模型训练; 在实时应用阶段, 配电网接收边缘计算装置的控制策略, 集群中的被控设备执行此策略, 实现电压控制功能。

在边缘侧, 考虑到集群内边缘计算装置算力有限与云边之间隐私保护的问题, 利用拆分学习的方法训练神经网络, 构建轻量化网络并实现加密功能, 将配电网侧传输的数据信息作为轻量化网络的输入。云边之间依靠神经网络中切割层加密数据代替原始数据进行交互, 实现了原始数据不上传到云侧, 通过模型拆分增强了隐私保护性能。同时, 不同集群对应的边缘计算装置中的轻量化网络模型可以设置成不同的结构, 大大增加了其他利益主体对某个集群的轻量化网络结构与原始数据的隐私攻击难度。

在云侧, 基于拆分学习构建大体量网络提取数据规律, 云端服务器承担了整个深度学习模型训练所需的大部分计算资源。在云端采用 FL 整合所有大体量网络模型的参数信息, 实现配电系统多集群的信息融合与数据协同。云端服务器的 FL 除了有数据协同的功能外, 也具备隐私保护功能, 使得标签数据不泄露到其他集群对应的大体量网络模型中。

## 2 DG 集群自适应可信协同决策方法

基于上述 SFL 框架, 实现配电网多集群可信协

同决策。首先基于 SFL 框架, 进行深度学习模型训练, 训练前需构建训练集结构和模型结构, 并根据训练集中的数据价值增添模型更新机制, 使模型训练的优化目标趋向于配电网最优运行状态。然后, 模型根据配电网源荷波动状态进行决策, 在此过程中, 也可根据设置的奖励机制对模型进行实时自适应更新。同时, 为了避免神经网络模型输出不确定对控制效果的不利影响, 拟在神经网络的输出端增添掩模机制, 来保证策略输出满足配电网被控设备的约束条件。

### 2.1 面向电压决策的深度学习模型构建

基于 SFL 框架构建配电网 DG 集群深度学习模型, 包括训练集结构和模型结构两个部分。

#### 2.1.1 训练集结构

假设在训练过程中集群  $n$  共采集  $H$  时刻的数据, 即训练集包含  $H$  个训练对象。每个单独的训练对象由  $h$  时刻的节点隐私数据信息矩阵  $\mathbf{X}_{n,h}$  和策略信息即标签矩阵  $\mathbf{Y}_{n,h}$  组成。

集群  $n$  的节点隐私数据信息矩阵  $\mathbf{X}_{n,h}$  包括  $h$  时刻配电网所有节点的注入有功功率和注入无功功率信息, 其中注入无功功率不包含此时刻 DG 无功出力, 矩阵结构如式(1)所示。

$$\mathbf{X}_{n,h} = \begin{bmatrix} x_{1,p}^{n,h} & x_{1,q}^{n,h} \\ x_{2,p}^{n,h} & x_{2,q}^{n,h} \\ \vdots & \vdots \\ x_{i,p}^{n,h} & x_{i,q}^{n,h} \\ \vdots & \vdots \\ x_{l,p}^{n,h} & x_{l,q}^{n,h} \end{bmatrix} \quad (1)$$

式中:  $x_{i,p}^{n,h}$ 、 $x_{i,q}^{n,h}$  分别表示第  $n$  个集群在  $h$  时刻节点  $i$  的注入有功、无功功率;  $l$  表示配电网所有节点个数。

由于本文方法采用的是分布式集群控制框架, 集群之间不相互传递量测到的隐私数据, 每个集群只拥有各自节点的数据。第  $n$  个集群包括若干节点  $i_a$ , 第  $n$  个集群内节点集合用  $I_n$  表示, 即  $i_a \in I_n$ , 节点隐私数据信息矩阵  $\mathbf{X}_{n,h}$  中仅有  $x_{i_a,p}^{n,h}$ 、 $x_{i_a,q}^{n,h}$  的量测数据信息;  $i_b$  表示配电网中不属于集群  $n$  的节点,  $i_b \notin I_n$ 。矩阵  $\mathbf{X}_{n,h}$  中  $x_{i_b,p}^{n,h}$  和  $x_{i_b,q}^{n,h}$  未知, 需用数据预处理后的平均状态量代替。

第  $n$  个集群的标签矩阵  $\mathbf{Y}_{n,h}$  包含  $h$  时刻配电网所有 DG 无功出力的策略信息, 如式(2)所示。

$$\mathbf{Y}_{n,h} = [y_1^{n,h}, y_2^{n,h}, \dots, y_r^{n,h}, y_R^{n,h}]^T \quad (2)$$

式中:  $y_r^{n,h}$  表示第  $n$  个集群在  $h$  时刻第  $r$  个 DG 的无

功出力策略； $R$  表示配电网所有 DG 的个数。

与节点隐私数据信息矩阵  $\mathbf{X}_{n,h}$  类似，每个集群只拥有各自集群内 DG 的数据，即第  $n$  个集群包括若干 DG，用  $r_a$  表示，集群内 DG 集合用  $R_n$  表示， $r_a \in R_n$ ，标签矩阵  $\mathbf{Y}_{n,h}$  只有  $y_{r_a}^{n,h}$  的量测信息； $r_b$  表示不属于第  $n$  个集群的 DG 序号， $r_b \notin R_n$ ；矩阵  $\mathbf{Y}_{n,h}$  中  $y_{r_b}^{n,h}$  未知，也需用数据预处理之后的平均状态量代替。可以看出标签矩阵  $\mathbf{Y}_{n,h}$  不涉及集群中节点信息，云侧大体量网络模型虽然输出了本集群内 DG 的策略信息，却不能确定 DG 安装的节点位置，这也在一定程度上提高了云边之间的隐私保护能力。

配电网拓扑信息矩阵  $\mathbf{A}$  表示配电网所有节点的连接关系，由于配电网结构固定不变，各个集群多个时刻采用的拓扑信息矩阵不变，矩阵结构如式(3)所示。

$$\mathbf{A} = \begin{bmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,j} & \cdots & a_{1,I} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,j} & \cdots & a_{2,I} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{i,1} & a_{i,2} & \cdots & a_{i,j} & \cdots & a_{i,I} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{I,1} & a_{I,2} & \cdots & a_{I,j} & \cdots & a_{I,I} \end{bmatrix} \quad (3)$$

式中： $a_{i,j}$  表示拓扑信息矩阵  $\mathbf{A}$  第  $i$  行、第  $j$  列元素，即节点  $i$ 、 $j$  的连接关系，其取值如式(4)所示。

$$a_{i,j} = \begin{cases} 0 & i, j \text{ 节点间没有线路连接} \\ 1 & i, j \text{ 节点间有线路连接} \end{cases} \quad (4)$$

由于训练集中的不同特征数据含义不同，其数量级和单位也不同，需要对采集到的数据进行规范化处理，本方法采用 Z-Score 标准化方法，处理后的数据近似符合标准正态分布，所以上文提到的未知数据预处理后的平均状态量可以设置为零。

### 2.1.2 模型结构

采用图卷积神经网络(graph convolutional neural networks, GCN)结合配电网多集群可信协同框架来提取配电网的特征信息，实现在保护节点数据隐私的前提下，以数据为基础构建配电网多集群控制策略信息提取模型。

GCN 相比于其他神经网络模型，具有可处理图数据结构的特点。由于配电网的节点隐私数据是依附于网络拓扑结构而存在，需要将配电网的拓扑信息与节点隐私数据信息进行有效结合，以便能更好地实现配电网多分布式电源集群可信协同决策。图卷积神经网络的图数据处理优势往往能满足这一要求，是建立配电网特征提取模型的最佳选择之一。

GCN 的层间传递结构如式(5)所示。

$$\mathbf{H}^{(g+1)} = \sigma \left( \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(g)} \mathbf{W}^{(g)} \right) \quad (5)$$

式中： $\sigma$  表示激活函数； $\tilde{\mathbf{D}}$  为对角矩阵， $\tilde{\mathbf{D}}_{ii} = \sum_j \tilde{\mathbf{A}}_{ij}$ ； $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{E}_I$ ， $\mathbf{E}_I$  为  $I$  阶单位矩阵； $\mathbf{H}^{(g)}$  表示第  $g$  卷积层的输出； $\mathbf{W}^{(g)}$  表示第  $g$  层可训练的权重矩阵。

在图卷积输入层输入节点隐私数据信息矩阵  $\mathbf{X}_{n,h}$ ，经过若干个图卷积隐藏层、图卷积切割层和线性层，在输出层输出拟合值。本方法采用渗漏型整流线性单元激活函数(LeakyReLU)，如式(6)和式(7)所示。

$$\sigma(x) = \text{LeakyReLU}(x, \beta = 0.3) \quad (6)$$

$$\text{LeakyReLU}(x, \beta) = \max(0, x) + \beta \times \min(0, x) \quad (7)$$

LeakyReLU 函数是经典 ReLU 激活函数的变体。该函数的特点是如果输入为负值，输出不恒为 0，且导数永远不为零。拟合效果优于 ReLU 函数。

由于训练集标签矩阵  $\mathbf{Y}_{n,h}$  的维度是  $R \times 1$ ，与配电网节点数无关，为适应图卷积神经网络的模型结构，需要在模型输出层之前增加一个线性层，选用 Linear 函数，如式(8)所示。

$$\mathbf{Y}_{1 \times R} = \sigma(\mathbf{Z}_{1 \times I} \mathbf{W}_{I \times R}) \quad (8)$$

式中： $\mathbf{Y}_{1 \times R}$  表示输出矩阵； $\mathbf{Z}_{1 \times I}$  表示最后一个图卷积层输出矩阵； $\mathbf{W}_{I \times R}$  表示参数矩阵。

由于所提方法属于有监督学习，应选取恰当的损失函数。本文选取均方误差来计算预测值与真实值的匹配程度，如式(9)所示。

$$\mathcal{L}_n = \sum_{h=1}^H \sum_{r=1}^R (\hat{y}_r^{n,h} - \hat{y}_r^{n,h})^2 \quad (9)$$

式中： $\mathcal{L}_n$  表示第  $n$  个集群对应的均方误差损失函数； $\hat{y}_r^{n,h}$ 、 $\hat{y}_r^{n,h}$  分别表示第  $n$  个集群在  $h$  时刻的第  $r$  个 DG 的预测值与真实值。

### 2.2 自适应奖励机制构建

由于本文方法的训练集数据采用实际量测数据，与最优数据有一定的差距，需要增添判断数据价值的自适应奖励机制。在模型训练过程中，自适应奖励机制的作用是根据训练集数据价值来判断数据优劣，使模型训练向拟合最优策略的方向进行。在决策过程中，模型中的自适应奖励机制也可根据测试日运行的实时变化进行模型自适应更新。

通过控制 DG 的无功出力来调节配电网的电压水平，为了减小系统电压偏差，拟根据集群内所有节点的电压情况调整对应的神经网络损失函数加权值，以使神经网络模型的输出值向减小电压偏差的方向更新为目的，设计的自适应奖励机制如下。

1) 参考文献[13], 采用敏感性高的电压平方偏差表达式, 计算平均电压偏差指标  $\delta_{n,h}$ , 如式(10)所示。

$$\delta_{n,h} = \frac{1}{\phi_n} \sum_{i=1}^{I_n} |V_{h,i}^2 - 1| \quad (10)$$

式中:  $\delta_{n,h}$  表示第  $n$  个集群中  $h$  时刻的平均电压偏差指标;  $\phi_n$  表示第  $n$  个集群中的节点个数;  $V_{h,i}$  表示  $h$  时刻节点  $i$  的电压。

2) 根据  $\delta_{n,h}$  调整  $h$  时刻对应的神经网络损失函数加权值  $w_h$ 。

损失函数加权值  $w_h$  需根据  $\delta_{n,h}$  进行调整, 形成自适应奖励机制, 损失函数加权值设计如图 2 所示。其中  $m_n$  表示第  $n$  个集群的电压偏差指标经验均值,  $s_n$  表示第  $n$  个集群的电压偏差指标经验标准差,  $b$  为自定义变量。

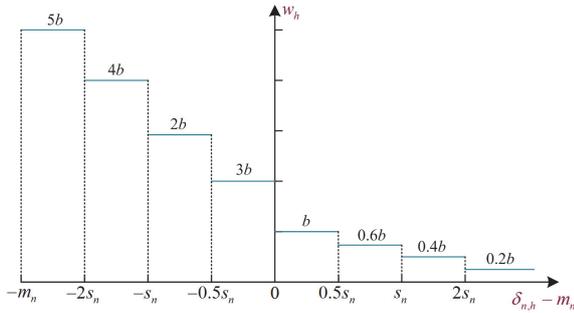


图 2 损失函数加权值设计图

Fig. 2 Design diagram of the weight of loss function

由图 2 可知,  $h$  时刻数据对应的  $\delta_{n,h}$  越小, 损失函数加权值  $w_h$  越大, 数据接近最优值, 在深度学习模型中增强了该数据的影响力。  $\delta_{n,h}$  较大的数据, 需减小其对应的损失函数加权值  $w_h$ , 以削弱该数据的影响力, 从而达到对原始数据进行优劣筛选的目的。

### 2.3 深度学习模型训练流程

基于 SFL 框架进行配电网 DG 集群深度学习模型训练, 流程如图 3 所示, 具体步骤如下所述。

1) 边缘侧轻量化模型与云侧大体量模型分别初始化各自的网络参数, 同时设置初始化训练轮数  $k=1$ 。

2) 配电网第  $n$  个集群采集配电网运行过程中的网络量测信息  $X_n$  与标签  $Y_n$ 。按照交互周期, 将  $X_n$  和  $Y_n$  数据信息打包传到第  $n$  个集群对应的边缘计算装置中的轻量化模型输入端。

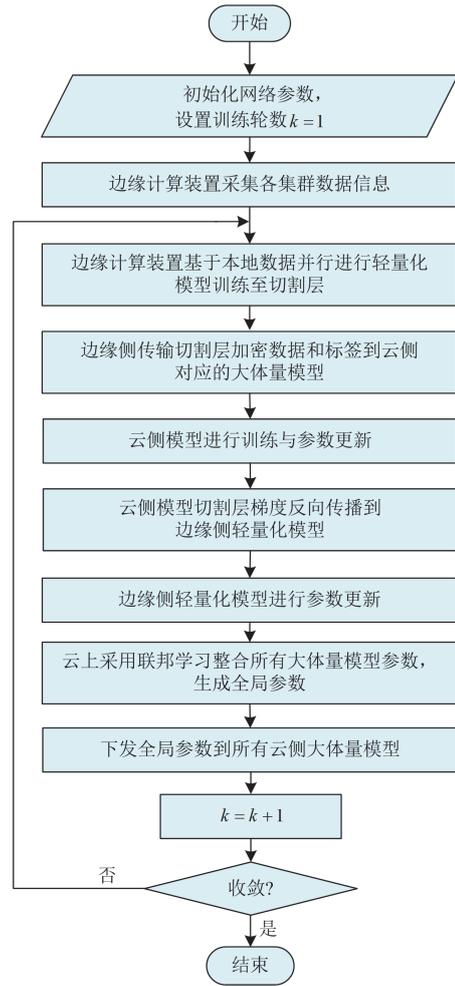


图 3 深度学习模型训练流程图

Fig. 3 Training flowchart of deep learning model

3) 边缘计算装置上的轻量化模型接收到配电网传输的  $X_n$ 、 $Y_n$  信息, 正向传播至轻量化模型的切割层, 并将切割层加密数据  $S_{k,n}$  与标签  $Y_n$  传输到云侧对应的大体量模型, 加密数据的生成过程如式(11)所示。

$$S_{k,n} = F_a(\omega_{k,n}^C, X_n) \quad (11)$$

式中:  $S_{k,n}$  表示第  $n$  个集群第  $k$  轮训练时从第  $g_n$  层切割层向第  $g_n+1$  层传输的加密数据;  $F_a$  表示边缘侧神经网络的正向传播函数;  $\omega_{k,n}^C$  表示第  $n$  个集群第  $k$  轮训练时对应的轻量化模型中网络的参数。

4) 云侧大体量模型对接收到的  $S_{k,n}$  和  $Y_n$  进行正向传播, 并在输出层生成损失函数, 如式(12)所示。

$$L_{k,n} = F_b(\omega_{k,n}^S, S_{k,n}, Y_n) \quad (12)$$

式中:  $L_{k,n}$  表示第  $n$  个集群第  $k$  轮训练时对应模型的损失函数;  $F_b$  表示云侧神经网络的正向传播函数;

$\omega_{k,n}^S$  表示第  $n$  个集群第  $k$  轮训练时对应的云侧大体量模型中网络的参数。

5) 云侧大体量模型根据  $L_{k,n}$  反向传播形成梯度数据, 更新云侧模型的网络参数, 并将切割层梯度传输给边缘侧的轻量化模型, 如式(13)和式(14)所示。

$$\omega_{k+1,n}^S = \omega_{k,n}^S - \eta B_{k,n} \quad (13)$$

$$C_{k,n} = F_b^{-1}(L_{k,n}) \quad (14)$$

式中:  $\eta$  表示训练时的学习率;  $B_{k,n}$  表示第  $n$  个集群第  $k$  轮训练时的梯度数据;  $C_{k,n}$  表示第  $n$  个集群第  $k$  轮训练时从第  $g_n + 1$  层向第  $g_n$  层传输的加密数据;  $F_b^{-1}$  表示云侧神经网络的反向传播函数。

6) 边缘侧模型反向传播切割层梯度数据  $C_{k,n}$ , 并更新边缘侧模型的网络参数, 如式(15)所示。

$$\omega_{k+1,n}^C = \omega_{k,n}^C - \eta C_{k,n} \quad (15)$$

7) 云端服务器根据联邦平均算法, 整合所有集群对应的云侧模型网络参数, 并根据全局参数更新云侧模型网络参数, 如式(16)、式(17)所示。

$$\omega_{k,G}^S = \frac{1}{N} \sum_{n=1}^N \omega_{k,n}^S \quad (16)$$

$$\omega_{k+1,n}^S = \omega_{k,G}^S \quad (17)$$

式中:  $\omega_{k,G}^S$  表示第  $k$  轮训练时基于联邦平均算法生成的云侧网络全局参数;  $N$  表示集群总数。

8) 设置训练轮数  $k = k + 1$ , 反复执行步骤 2)~步骤 8), 直至神经网络损失函数收敛。

综上所述, 基于 SFL 框架的训练方式在保护多利益主体隐私的前提下, 充分考虑边缘计算装置算力限制, 打破集群之间的数据孤岛, 实现多集群之间的信息融合与协同。

#### 2.4 基于掩模机制的输出策略矫正方法

在配电网可信协同决策阶段, 由于基于图卷积神经网络的数据驱动方法具有输出不确定性, 需要在模型中加入掩模机制来保证模型输出满足 DG 无功出力约束。

DG 作为被控对象, 需满足如式(18)~式(20)所示的约束。

$$P_{r,\min} \leq P_r \leq P_{r,\max} \quad (18)$$

式中:  $P_r$ 、 $P_{r,\max}$  和  $P_{r,\min}$  分别表示第  $r$  个 DG 的有功功率及其最大、最小值。

$$Q_{r,\min} \leq Q_r \leq Q_{r,\max} \quad (19)$$

式中:  $Q_r$ 、 $Q_{r,\max}$  和  $Q_{r,\min}$  分别表示第  $r$  个 DG 的无功功率及其最大、最小值。

$$P_r^2 + Q_r^2 \leq S_r^2 \quad (20)$$

式中:  $S_r$  表示第  $r$  个 DG 的容量。

增添掩模机制来保证输出策略值满足约束条件, 步骤如下。

1) 为满足 DG 无功出力约束, 将输出的 DG 无功出力值  $Q_r$  按照式(21)进行处理。

$$Q_r = \begin{cases} Q_{r,\min} & Q_r < Q_{r,\min} \\ Q_r & Q_{r,\min} \leq Q_r \leq Q_{r,\max} \\ Q_{r,\max} & Q_r > Q_{r,\max} \end{cases} \quad (21)$$

2) 为满足 DG 容量约束, 将  $Q_r$  按照式(22)进行处理。

$$Q_r = \begin{cases} -\sqrt{S_r^2 - P_r^2} & P_r^2 + Q_r^2 > S_r^2, Q_r < 0 \\ Q_r & P_r^2 + Q_r^2 \leq S_r^2 \\ \sqrt{S_r^2 - P_r^2} & P_r^2 + Q_r^2 > S_r^2, Q_r > 0 \end{cases} \quad (22)$$

由于训练集是实际运行数据, 标签数据满足约束, 训练好的深度学习模型大概率能拟合出满足约束的分布式电源输出策略, 所以提出的掩模机制只针对个别的数据输出。

综上所述, 配电网自适应可信协同决策方法可实现高效快速源荷响应, 模型能够根据运行状态进行实时更新, 掩模机制保障了输出策略的合理性。

### 3 算例分析

#### 3.1 算例设计

本文采用广州蕉门算例, 其拓扑和分区结构如图 4 所示。其中, 额定负荷总有功功率为 10.05 MW, 总无功功率为 7.54 Mvar, 额定电压为 10.5 kV。

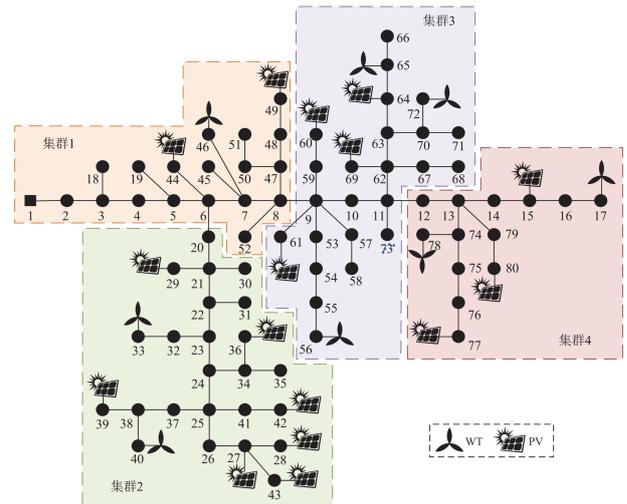


图 4 广州蕉门算例图

Fig. 4 Case of Jiaomen in Guangzhou

在蕉门算例中接入 8 组风电机组和 16 组光伏系统。总接入额定有功容量为 12.5 MW, 其具体额

定容量及接入位置如附录 A 表 A1 所示。

本文采用梯度下降法训练神经网络。基础模型训练集选取 1 天的配电网运行数据, 步长为 10 s, 总采样数据个数  $H = 8640$ 。其中, 节点隐私数据信息矩阵的维度为  $80 \times 2$ , 不同集群的标签矩阵数据结构不同, 维度为集群内所含 DG 的个数  $\times 1$ , 拓扑信息矩阵维度为  $80 \times 80$ 。设置配电网电压幅值的运行上、下限分别为 1.05 和 0.95。根据经验值, 图 2 中的  $m_n (n=1,2,3,4)$  分别取 0.011 83、0.018 88、0.014 69、0.014 58;  $s_n (n=1,2,3,4)$  分别取 0.011 18、0.018 72、0.011 98、0.011 58; 取  $b=1$ 。

测试日的源荷波动曲线如图 5 所示。测试集选取测试日(1 天)配电网的实际运行数据, 训练步长和矩阵维度与训练集相同。在实时应用阶段, 为适应配电网源荷波动, 边缘计算装置采集配电网终端的数据作为深度学习模型的输入, 进而拟合 DG 电压控制策略, 终端接收此策略并执行, 使配电网能根据源荷波动自动调整 DG 出力。在此过程中, 模型根据实时数据进行更新, 能自动调整适应源荷出力。

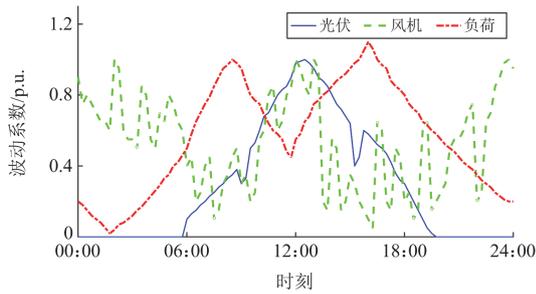


图 5 源荷波动曲线

Fig. 5 Source-load fluctuation curve

在训练过程中, 需要合理设置配电网中神经网络模型超参数, 如表 1 所示。

表 1 神经网络超参数

Table 1 Neural network hyperparameters

模型位置	集群 1 边缘侧	集群 2 边缘侧	集群 3 边缘侧	集群 4 边缘侧	云侧
网络层数	3	2	3	4	7
每层节点数	4,8,7	3,7	3,5,7	3,4,6,7	7,6,5,4,3,2,1
基础模型学习率	0.005				
更新时学习率	0.0005				
更新周期	4 h				
批次大小	8640				

测试程序基于 Pycharm 软件开发, 并基于 Pytorch 库实现对图卷积神经网络的训练, 软件环境为 Python3.9。计算机硬件环境为 Intel(R) Core(TM) i7-9750H CPU, 主频为 2.60 GHz, 内存为 16 GB。

## 3.2 结果分析

### 3.2.1 电压控制效果分析

本节取以下 4 种方案进行控制效果的对比。

方案 I: DG 无功出力为 0, 得到配电网初始运行状态;

方案 II: 利用本文方法, 决策 DG 无功出力, 获得配电网的运行状态;

方案 III: 利用集中式优化方法对 DG 无功出力进行优化;

方案 IV: 利用多智能体深度确定性策略梯度 (multi-agent deep deterministic policy gradient, MADDPG) 控制方法<sup>[23-24]</sup>, 决策被控设备的出力, 获得配电网运行状态。

引入平均电压偏差指标 (average voltage deviation, AVD) 计算全网络的平均电压偏差, 更加直观地反映了不同方案下的电压波动大小。

$$\varepsilon = \frac{1}{H} \sum_{h=1}^H \sum_{i=1}^I |V_{h,i}^2 - 1| \quad (23)$$

式中:  $\varepsilon$  表示所提方法或者 MADDPG 方法的 AVD。

最优率  $\ell$  定义为

$$\ell = \left( 1 - \frac{\varepsilon - \varepsilon_1}{\varepsilon_1 - \varepsilon_0} \right) \times 100\% \quad (24)$$

式中:  $\varepsilon_1$  表示集中式优化方法的 AVD;  $\varepsilon_0$  表示 DG 无功出力为 0 时的 AVD。

方案 I、II、III 的电压控制结果对比如表 2 所示。

表 2 不同方案电压控制结果对比

Table 2 Comparison of voltage control results of different schemes

方案	电压最小值/p.u.	电压最大值/p.u.	AVD/p.u.	最优率/%
I	0.9354	1.0218	2.9159	0
II	0.9688	1.0236	1.2024	65.91
III	0.9711	1.0044	0.3162	100.00

方案 I 与方案 II 的电压极值偏差对比如图 6(a) 所示。可以看出, 方案 II 与方案 I 相比, AVD 明显减小, 最优率大幅增大, 证明了本文所提方法的有效性。当 DG 无功不出力时, 配电网会有剧烈的电压波动且有电压越限的现象。采用本文方法对 DG 的无功出力进行控制后, 电压控制效果明显提升, 解决了 DG 无功不出力场景下电压波动大与电压越限的问题。通过控制 DG 的无功出力, 使系统电压维持在了一个安全运行的水平。

本文方法有着极强的隐私保护优势, 在训练过程中, 边缘侧网络模型正向传播过程相当于加密过程, 原始数据无需上传到云侧。并且在保障配电网集群之间数据安全的基础上, 实现了多集群之间的数据融合与区域协同。现从电压控制效果、隐私性

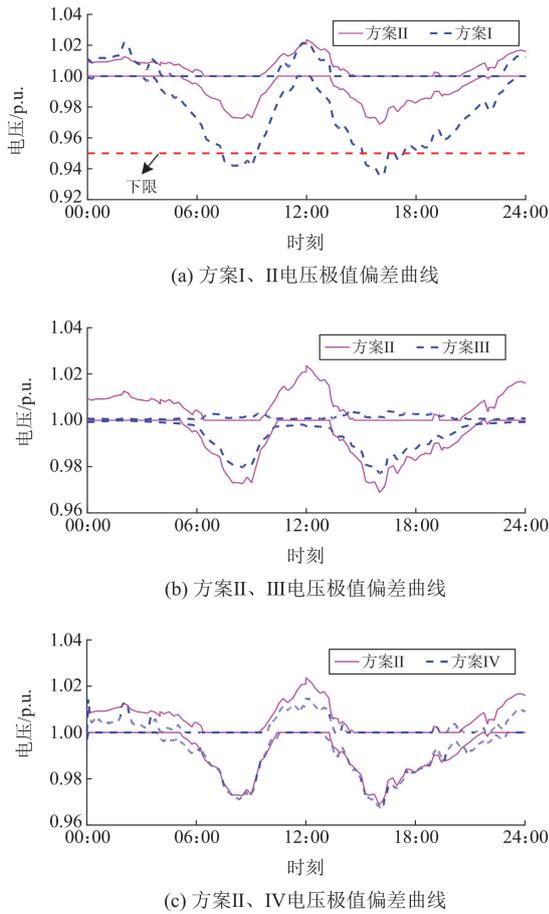


图 6 电压极值偏差对比

Fig. 6 Comparison of voltage extreme deviations

能等方面与 MADDPG 电压控制方法进行对比，如表 3 所示。

表 3 本文方法与 MADDPG 方法对比

Table 3 Comparison of the method in this paper and MADDPG method

方案	AVD/ p.u.	最优率/%	自适应 筛选能力	云边之间传输 数据类型	集群间是否 共享数据
II	1.2024	65.91	具备	加密数据	否
IV	1.0046	73.52	具备	原始数据	是

方案 II 与方案 IV 的电压极值偏差对比如图 6(c) 所示。可以看出两种方案的最优率相近，说明了本文方法在控制能力上能达到与 MADDPG 方法的相似效果。本文方法运用了 SFL 框架的优势，节点原始数据无需上传到云端，各集群之间不进行经验共享，相比于 MADDPG 方法具有更强的隐私保护性能，同时也具备自适应筛选能力。

### 3.2.2 自适应奖励机制有效性分析

在基于图卷积神经网络构建的配电网深度学习模型中，为实现对数据的自适应筛选功能，设置了

相应的奖励机制。在神经网络初始化随机值相同的情况下，比较集群 4 中有奖励机制和无奖励机制的情景。当无奖励机制时， $w_h$  恒为 1。图 7 为本文算例集群 4 对应的神经网络模型的收敛情况曲线。

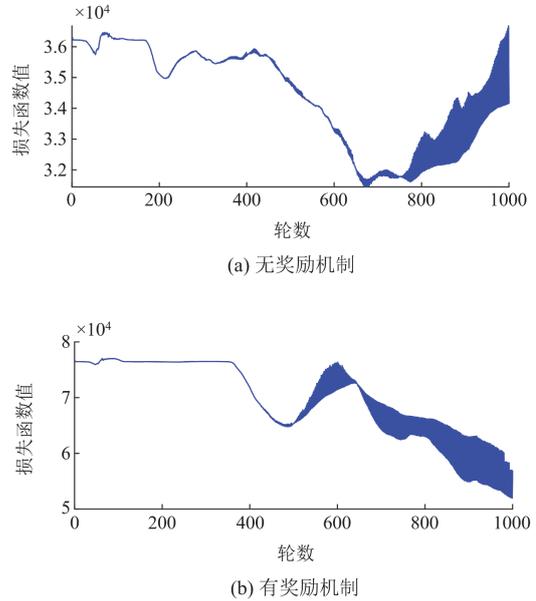


图 7 集群 4 神经网络收敛情况曲线

Fig. 7 Convergence curve of neural network in cluster 4

对比图 7(a)与图 7(b)，有奖励函数时模型经过 1000 轮迭代后损失函数较初始模型损失函数值显著下降，且呈现收敛趋势；在无奖励函数的情况，损失函数值在 700—1000 轮迭代时无下降趋势且不收敛。可以看出，有奖励机制时神经网络收敛性能远远好于无奖励机制的情况，说明了奖励机制在一定程度上能根据数据价值对数据进行优劣筛选，并改善神经网络的收敛性能。

综上所述，由多种方案对比可知，本文所提方法能对配电网电压进行有效控制，能有效抑制电压波动与解决电压越限问题。在新能源接入时，本文调压方法能减小电压波动，能够有效消纳新能源高比例接入，提升新能源的承载能力。最后，根据神经网络的收敛情况说明了自适应奖励机制的可行性与有效性。

## 4 结语

本文针对高比例 DG 接入配电网的电压控制问题，考虑多利益主体间的数据隐私保护，设计了基于 SFL 的配电网多集群控制框架。同时为保证电压控制效果，在模型中引入自适应奖励机制来优化控制策略，提出了分布式电源集群自适应可信协同决策方法。最后，在广州蕉门算例上验证了所提方法

的可行性, 本文所提方法抑制了电压波动, 具有良好的电压控制效果。

为保障电网安全稳定运行, 后续研究将探讨有限数据隐私保护机制, 以确保电网管理部门能够获取必要的用电数据。

## 附录 A

表 A1 分布式电源额定容量与接入位置  
Table A1 Distributed generator rated capacity  
and access location

所属 集群	接入 位置	有功容量/ kW	无功容量/ kvar	视在容量/ kVA	类型
1	44	500	500	750	光伏
	46	500	500	750	风机
	49	500	500	750	光伏
2	28	600	600	900	光伏
	29	600	600	900	光伏
	33	600	600	900	风机
	36	600	600	900	光伏
	39	600	600	900	风机
	40	600	600	900	光伏
	27	600	600	900	光伏
	43	600	600	900	光伏
3	64	600	600	900	光伏
	65	600	600	900	风机
	72	600	600	900	风机
	56	600	600	900	风机
	60	600	600	900	光伏
	61	600	600	900	光伏
4	69	600	600	900	风机
	15	400	400	600	光伏
	17	400	400	600	风机
	77	400	400	600	光伏
	78	400	400	600	风机
	80	400	400	600	光伏

## 参考文献

- [1] 尚博文, 徐铭铭, 张金帅, 等. 高比例分布式光伏接入背景下配电网电压调控方法研究综述[J]. 智慧电力, 2024, 52(12): 1-11.  
SHANG Bowen, XU Mingming, ZHANG Jinshuai, et al. Review of voltage regulation methods in distribution networks with high proportions of distributed photovoltaic integration[J]. Smart Power, 2024, 52(12): 1-11.
- [2] 陈一丰, 黄铭浩, 董树锋. 计及配电侧分布式电源的输配协同高收敛性最优潮流研究[J]. 电力工程技术, 2024, 43(4): 36-44.  
CHEN Yifeng, HUANG Minghao, DONG Shufeng. Research on improving the convergence of optimal power flow of transmission-distribution-coupled networks[J]. Electric Power Engineering Technology, 2024, 43(4): 36-44.
- [3] 段贵超, 王恭, 曹生现, 等. 虚拟电厂运行策略及 DG 分布式控制研究[J]. 发电技术, 2024, 45(4): 765-771.  
DUAN Guichao, WANG Gong, CAO Shengxian, et al. Research on operation strategy of virtual power plant and distributed control of DG[J]. Power Generation Technology, 2024, 45(4): 765-771.
- [4] AHMED M M N, AHMED A H, MAGDI M E, et al. Voltage imbalance mitigation in an active distribution network using decentralized current control[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 332-348.
- [5] 刘水, 张胜强, 唐伟华, 等. 柔性有载调压变压器电压无功协调控制策略[J]. 电力工程技术, 2024, 43(6): 203-213.  
LIU Shui, ZHANG Shengqiang, TANG Weihua, et al. Voltage and reactive power coordinated control strategy for flexible on-load tap changer[J]. Electric Power Engineering Technology, 2024, 43(6): 203-213.
- [6] XU Biao, ZHANG Guiyuan, LI Ke, et al. Reactive power optimization of a distribution network with high-penetration of wind and solar renewable energy and electric vehicles[J]. Protection and Control of Modern Power Systems, 2022, 7(4): 801-813.
- [7] 钱乙卫, 田浩, 刘财华, 等. 考虑概率分布的分布式光伏无功下垂控制策略[J]. 发电技术, 2024, 45(2): 273-281.  
QIAN Yiwei, TIAN Hao, LIU Caihua, et al. Droop control strategy of distributed photovoltaic reactive power considering probability distribution[J]. Power Generation Technology, 2024, 45(2): 273-281.
- [8] 郭雪丽, 胡志勇, 王爽, 等. 考虑大规模风光分层接入的配电网多层协调无功优化方法[J]. 电力系统保护与控制, 2024, 52(12): 113-122.  
GUO Xueli, HU Zhiyong, WANG Shuang, et al. A multi-layer coordinated reactive power optimization method for a distribution network considering large-scale distributed wind-photovoltaic hierarchical access[J]. Power System Protection and Control, 2024, 52(12): 113-122.
- [9] CUFFE P, OCHOA L F. A voltage control scheme for generation-dominated networks to maximize power export[J]. IEEE Transactions on Power Systems, 2018, 33(6): 7321-7323.
- [10] HUO Yanda, LI Peng, JI Haoran, et al. Data-driven coordinated voltage control method of distribution networks with high DG penetration[J]. IEEE Transactions on Power Systems, 2022, 38(2): 1543-1557.
- [11] 黄伟, 李宁坤, 李玟萱, 等. 考虑多利益主体参与的主动配电网双层联合优化调度[J]. 中国电机工程学报,

- 2017, 37(12): 3418-3428, 3669.
- HUANG Wei, LI Ningkun, LI Wenxuan, et al. Bi-level joint optimization dispatch of active distribution network considering the participation of multi-stakeholder[J]. Proceedings of the CSEE, 2017, 37(12): 3418-3428, 3669.
- [12] 徐博涵, 向月, 潘力, 等. 基于深度强化学习的含高比例可再生能源配电网就地分散式电压管控方法[J]. 电力系统保护与控制, 2022, 50(22): 100-109.
- XU Bohan, XIANG Yue, PAN Li, et al. Local decentralized voltage management of a distribution network with a high proportion of renewable energy based on deep reinforcement learning[J]. Power System Protection and Control, 2022, 50(22): 100-109.
- [13] 张梓泉, 崔明建, 张程彬, 等. 基于反事实多智能体强化学习和有功无功协同控制的配电网电压优化[J]. 电力系统保护与控制, 2024, 52(18): 76-86.
- ZHANG Zixiao, CUI Mingjian, ZHANG Chengbin, et al. Active and reactive power coordinated optimal voltage control of a distribution network based on counterfactual multi-agent reinforcement learning[J]. Power System Protection and Control, 2024, 52(18): 76-86.
- [14] 吴文传, 张伯明, 孙宏斌, 等. 主动配电网能量管理与分布式资源集群控制[J]. 电力系统自动化, 2020, 44(9): 111-118.
- WU Wenchuan, ZHANG Boming, SUN Hongbin, et al. Energy management and distributed energy resources cluster control for active distribution networks[J]. Automation of Electric Power Systems, 2020, 44(9): 111-118.
- [15] ZHAO Jinli, ZHANG Ziqi, YU Hao, et al. Cloud-edge collaboration-based local voltage control for DGs with privacy preservation[J]. IEEE Transactions on Industrial Informatics, 2022, 19(1): 98-108.
- [16] 蒲天骄, 杜帅, 李焯, 等. 面向隐私保护基于联邦强化学习的分布式电源协同优化策略[J]. 电力系统自动化, 2023, 47(8): 62-70.
- PU Tianjiao, DU Shuai, LI Ye, et al. Collaborative optimization strategy of distributed generators based on federated reinforcement learning for privacy preservation[J]. Automation of Electric Power Systems, 2023, 47(8): 62-70.
- [17] WANG Yi, GAO Ning, HUG G. Personalized federated learning for individual consumer load forecasting[J]. CSEE Journal of Power and Energy Systems, 2022, 9(1): 326-330.
- [18] 李锦辉, 吴毓峰, 余涛, 等. 数据孤岛下基于联邦学习的用户电价响应刻画及其应用[J]. 电力系统保护与控制, 2024, 52(6): 164-176.
- LI Jinhui, WU Yufeng, YU Tao, et al. Characterization of user price response behavior and its application based on federated learning considering a data island[J]. Power System Protection and Control, 2024, 52(6): 164-176.
- [19] 韩一宁, 崔明建, 罗光浩, 等. 基于自适应联邦学习的输配网动-静态综合状态估计方法研究[J/OL]. 中国电机工程学报: 1-15[2025-01-24]. <https://link.cnki.net/urlid/11.2107.tm.20250124.1046.010>
- HAN Yining, CUI Mingjian, LUO Guanghao, et al. An integrated dynamic-static state estimation method for transmission and distribution networks based on self-adaptive federated learning[J/OL]. Proceedings of the CSEE: 1-15[2025-01-24]. <https://link.cnki.net/urlid/11.2107.tm.20250124.1046.010>
- [20] LI Yehui, YAO Ruiyang, QIN Dalin, et al. Lightweight federated learning for on-device non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2025, 16(2): 1950-1961.
- [21] THAPA C, ARACHCHIGE P C M, CAMTEPE S, et al. Splitfed: when federated learning meets split learning[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(8): 8485-8493.
- [22] LI Yehui, QIN Dalin, POOR H V, et al. Introducing edge intelligence to smart meters via federated split learning[J]. Nature Communications, 2024, 15(1): 9044.
- [23] 李付强, 张文朝, 潘艳, 等. 基于改进深度确定性策略梯度算法的电压无功优化策略[J]. 智慧电力, 2024, 52(5): 1-7, 30.
- LI Fuqiang, ZHANG Wenchao, PAN Yan, et al. Reactive voltage optimization strategy based on improved depth deterministic strategy gradient algorithm[J]. Smart Power, 2024, 52(5): 1-7, 30.
- [24] 刘洋, 伍双喜, 朱誉, 等. 计及隐私保护的多智能体深度强化学习有源配电网电压控制策略[J]. 智慧电力, 2024, 52(12): 104-111.
- LIU Yang, WU Shuangxi, ZHU Yu, et al. Multi-agent deep reinforcement learning voltage control strategy for active distribution networks considering privacy protection[J]. Smart Power, 2024, 52(12): 104-111.

收稿日期: 2025-01-28; 修回日期: 2025-04-16

作者简介:

崔婧琪(2000—), 女, 硕士研究生, 研究方向为智能配电网优化运行; E-mail: cuijingqi@tju.edu.cn

冀浩然(1991—), 男, 通信作者, 博士, 教授, 研究方向为智能配电网优化运行; E-mail: jihaoran@tju.edu.cn

李鹏(1981—), 男, 博士, 教授, 研究方向为分布式发电与智能配电网的运行、仿真与分析。E-mail: lip@tju.edu.cn

(编辑 张颖)