



数字孪生辅助的智能楼宇多模态通信资源管理方法

石琰^{1,2}, 刘朋矩¹, 杜治钢¹, 张孙烜¹, 周振宇¹, 白晖峰³, 何国庆⁴, 孙文文⁴, 马跃⁵

- (1. 华北电力大学新能源电力系统国家重点实验室, 北京 102206;
2. 广州城市理工学院, 广东 广州 510800; 3. 北京智芯微电子科技有限公司, 北京 100192;
4. 中国电力科学研究院有限公司新能源与储能运行控制国家重点实验室, 北京 100192;
5. 国网冀北电力有限公司, 北京 100054)

摘要: 多模态通信网络为智能楼宇能源调控数据的采集、传输、处理以及能源调控模型训练提供了通信支撑。数字孪生可以提供计算资源、信道特性等状态估计, 辅助多模态通信资源管理优化, 提高能源调控模型训练精度。然而, 数字孪生辅助的智能楼宇多模态通信资源管理面临能源调控模型训练误差大、多时间尺度资源分配耦合、模型训练精度提高与能耗优化相互矛盾等挑战。针对上述挑战, 提出基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法, 通过联合优化大时间尺度网关选择和小时间尺度信道分配与功率控制, 最小化全局模型损失函数和能耗加权和。仿真结果表明, 所提算法可以提高全局模型损失函数和能耗加权和性能, 保障智能楼宇能源精准调控需求, 促进智能楼宇能源调控低碳运行。

关键词: 智能楼宇; 数字孪生; 能源调控; 联邦学习; 匹配理论; 上置信区间

中图分类号: TN914

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023017

Digital twin-assisted multi-mode communication resource management methods for smart buildings

SHI Cheng^{1,2}, LIU Pengju¹, DU Zhigang¹, ZHANG Sunxuan¹,
ZHOU Zhenyu¹, BAI Huifeng³, HE Guoqing⁴, SUN Wenwen⁴, MA Yue⁵

1. State Key Laboratory of Alternate Electrical Power System with
Renewable Energy Sources, North China Electric Power University, Beijing 102206, China
2. Guangzhou City University of Technology, Guangzhou 510800, China
3. Beijing Smartchip Microelectronics Technology Co., Ltd., Beijing 100192, China
4. State Key Laboratory of Operation and Control of Renewable
Energy and Storage, China Electric Power Research Institute, Beijing 100192, China
5. State Grid Jibei Electric Power Co., Ltd., Beijing 100054, China

Abstract: The multi-mode communication network provides communication support for the collection, transmission, and processing of energy regulation data and the training of energy regulation models for smart buildings. Digital

收稿日期: 2022-07-14; 修回日期: 2023-01-09

通信作者: 周振宇, zhenyu_zhou@ncepu.edu.cn

基金项目: 国家电网有限公司总部管理科技项目 (No.52094021N010 (5400-202199534A-0-5-ZN))

Foundation Item: The Science and Technology Project of State Grid Corporation of China (No.52094021N010 (5400-202199534A-0-5-ZN))

twin can provide state estimation of computing resources and channel characteristics, assist in the multi-mode communication resource optimization management, and improve the training precision of energy regulation models. However, the digital twin-assisted multi-mode communication resource management of smart buildings still face challenges such as large training error of energy regulation model, coupling of multi-timescale resource allocation, and contradictions between training precision improvement of energy regulation model and energy consumption optimization. Aiming at the above challenges, a multi-timescale communication resource management optimization algorithm based on digital twin and empirical matching learning was proposed. The weighted sum of global model loss function and energy consumption was minimized by jointly optimizing the large-timescale gateway selection and small-timescale channel allocation and power control. Simulation results show that the proposed algorithm can improve the performance of weighted sum of global model loss function and energy consumption, ensure the precise energy regulation requirement and promote the low-carbon operation of smart buildings.

Key words: smart building, digital twin, energy regulation, federated learning, matching theory, upper confidence bound

0 引言

智能楼宇的低碳运行是构建新型电力系统的重要环节,也是“十四五”规划中智慧城市建设的重要组成部分^[1]。智能楼宇集成通信和控制领域的先进技术,通过能源调控,实现智能楼宇电气设备的控制和管理优化^[2-3]。数字孪生技术通过构建物理实体的数字模型,打造实体空间和数字空间的数据交互路径,对能源调控进行全周期数字化处理,实现调控多源数据信息融合^[4-7]。为了提高智能楼宇能源调控准确性,通过部署大量通信终端采集能源调控数据,并利用交直流电力线载波、无线局域网(wireless local area network, WLAN)和微功率无线等多模态通信传输数据至边缘智能网关,为能源调控模型训练提供样本数据集,从而实现能源调控模型的精确训练^[8-10]。

联邦学习能够实现全局模型训练和原始数据传输的解耦,保障数字孪生能源调控模型训练的安全性^[11-13]。基于联邦学习的智能楼宇能源调控模型构建需要通信终端传输样本数据集至边缘智能网关进行边缘模型训练,并将边缘模型参数上传至集中控制器进行全局聚合。通过为通信终端选择计算能力强的边缘智能网关、分配高增益多模态信道以及控制终端的传输功率,减小全局模

型损失函数和训练能耗。数字孪生能够提供计算资源、信道特性等状态估计,辅助多模态通信资源的优化管理^[14]。然而,数字孪生辅助的智能楼宇多模态通信资源管理面临以下挑战。

首先,由于智能楼宇多模态通信网络的异构性、动态性和信息不确定性,多模态通信资源管理与能源调控模型训练适配性差,导致全局模型损失函数大,能源调控模型训练精度低。其次,网关选择需要大时间尺度优化,从而避免频繁切换导致的通信开销;而信道分配和功率控制需要小时间尺度优化,从而响应快速变化的信道状态。此外,由于网关与终端之间的距离以及信道增益具有差异性,大时间尺度网关选择会影响小时间尺度信道分配与功率控制;传输样本数量不同导致模型训练精度和能耗存在差异,小时间尺度信道分配与功率控制会反过来影响大时间尺度网关选择。最后,模型精度优化与能耗优化相互矛盾,提高模型精度需要终端传输更多的样本,导致样本数据集的传输能耗与边缘模型训练能耗增大;降低样本数据集的传输能耗与边缘模型训练能耗需要减少终端传输的样本,导致模型精度下降。

在基于数字孪生的通信资源管理方面已有相关研究。文献[15]研究了一种基于数字孪生的空中



辅助动态车联网,提出了一种两阶段的资源管理激励机制,最大化车辆满意度和能效。然而,上述文献仅考虑了单一时间尺度的资源管理,网络资源开销过大,无法适用于更加复杂的多时间尺度资源管理场景。文献[16]研究了一种数字孪生辅助的车联网边缘智能协作方案,通过数字孪生辅助通信、计算和缓存资源管理学习,最小化网络响应时延。然而,上述文献忽略了多时间尺度资源管理之间的耦合,并且只考虑了单一性能指标优化,难以满足网络差异化性能需求。文献[17]研究基于数字孪生和联邦学习的无线网络,通过联合优化数据批次大小和带宽分配,提高系统的可靠性和安全性。然而,上述文献无法实现联邦学习模型训练的精度优化,难以满足智能楼宇能源调控的准确性需求。

针对上述问题,本文提出数字孪生辅助的智能楼宇多模态通信资源管理方法,通过联合优化通信终端大时间尺度网关选择和小时间尺度信道分配与功率控制,构建智能楼宇高精度能源调控模型。首先,构建数字孪生辅助的智能楼宇全局模型损失函数和能耗联合优化问题。其次,提出基于升价经验匹配的大时间尺度网关选择优化算法以及基于数据集感知上置信区间(upper confidence bound, UCB)的小时间尺度信道分配与功率控制优化算法,求解联合优化问题。最后,通过仿真分析验证所提算法的有效性。本文的主要贡献如下。

(1) 高精度智能楼宇能源调控模型的训练:利用基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法,最小化全局模型损失函数,提升能源调控模型精度。

(2) 数字孪生辅助的多时间尺度网关选择、信道分配与功率控制的联合优化:基于数字孪生提供的智能楼宇状态信息估计,利用基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法解决网关选择、信道分配与功率控制之间

的耦合问题,通过在大时间尺度上基于升价经验匹配优化网关选择,在小时间尺度上基于数据集感知 UCB 优化信道分配与功率控制,实现多时间尺度通信资源管理优化。

(3) 全局模型精度与能耗性能的动态调整和折中:本文构建数字孪生辅助的智能楼宇全局模型精度与能耗联合优化问题,将优化目标设置为全局模型损失函数与能耗的加权和,通过调整权重来动态权衡全局模型损失函数与能耗性能,在实现模型精度与能耗性能折中的同时,满足不同类型的电气设备对全局模型精度和能耗的差异化需求。当权重增大时,减小能耗能够使奖励迅速增大,使得集中控制器在管理多模态通信资源时优先满足需求更低能耗的电气设备;当权重减小时,减小全局模型损失函数能够使奖励迅速增大,使得集中控制器在管理多模态通信资源时优先满足需求更高全局模型精度的电气设备。

1 系统模型

本文考虑数字孪生辅助的智能楼宇多模态通信资源管理场景,通过数字孪生辅助的联邦学习,构建智能楼宇能源调控模型。该场景包括设备层、边缘层和数字孪生层,如图 1 所示。设备层包括电气设备和与电气设备相连的通信终端,负责采集电力数据,形成样本数据集,并通过多模态通信网络上传到边缘层。边缘层包括边缘智能网关和集中控制器。边缘智能网关根据设备传输的数据集训练边缘模型,并将训练后的模型参数上传至集中控制器。集中控制器基于联邦学习,对边缘模型参数进行全局聚合,训练全局能源调控模型。此外,集中控制器还负责智能楼宇多模态通信资源管理,包括设备的网关选择、信道分配和功率控制。边缘层通过多模态通信与设备层进行数据交互,所采用的多模态通信方式包括交直流载波、WLAN 和微功率无线通信。电气设备依据自身所处的交流配电网或直流配电网,配置对应

的交流载波通信模块或直流载波通信模块。数字孪生层由集中控制器维护, 并通过与设备实时交互, 保持与物理实体网络同步, 从而提供状态信息估计, 辅助多模态通信资源管理。




图1 数字孪生辅助的智能楼宇多模态通信资源管理场景

假设设备层共有 N 个设备进行数据集上传, 其集合表示为 $U=\{U_1, U_2, \dots, U_n, \dots, U_N\}$; 边缘层共有 M 个边缘智能网关提供通信覆盖及边缘模型训练, 其集合表示为 $G=\{G_1, G_2, \dots, G_m, \dots, G_M\}$; 设备和网关之间通过 K 个多模态信道进行通信, 其集合表示为 $C=\{C_1, C_2, \dots, C_k, \dots, C_K\}$ 。其中, $C_k, k=1, \dots, K_1$ 表示交直流载波信道, $C_k, k=K_1+1, \dots, K_2$ 表示 WLAN 信道, $C_k, k=K_2+1, \dots, K$ 表示微功率无线信道。

本文将总时间划分为 I 个大时间尺度, 称为时段; 每个时段包含 T_0 个小时时间尺度, 称为迭代, 即总时间共划分为 $T=IT_0$ 次迭代。定义时段集合为 $I_s=\{1, 2, \dots, i, \dots, I\}$, 迭代集合为 $T_s=\{1, 2, \dots, t, \dots, T\}$ 。若第 t 次迭代位于第 i 个时段内, 其关系可以表示为 $i=\lfloor t/T_0 \rfloor + 1$, 符号 $\lfloor \cdot \rfloor$ 表示向下取整。每次迭代由 3 个过程组成, 分别为设备数据集上传、边缘模型训练和全局模型聚合。

1.1 设备数据集上传模型

网关利用样本数据集 $\Pi_n(t)$ 训练设备 U_n 的边缘模型, 并在数字孪生层构建设备 U_n 的数字孪生体。在每个时段开始时, 设备进行网关选择; 在每次迭代开始时, 设备进行信道分配与功率控制。定义大时间尺度网关选择变量 $x_{n,m}(i) \in \{0, 1\}$, $x_{n,m}(i)=1$ 表示设备 U_n 在第 i 个时段内选择网关 G_m 进行数据集传输, 否则 $x_{n,m}(i)=0$; 定义小时间尺度信道分配变量 $z_{n,k}(t) \in \{0, 1\}$, $z_{n,k}(t)=1$ 表示设备 U_n 在第 t 次迭代时选择信道 C_k 进行数据集传输, 否则 $z_{n,k}(t)=0$ 。由于网关的计算资源限制, 网关 G_m 最多可以同时为 q_m 个设备提供边缘模型训练, 并称 q_m 为网关 G_m 的配额。

定义功率控制变量 $\delta_n(t)$, 用于表示设备 U_n 在第 t 次迭代时的传输功率与最大传输功率 $P_{k,\max}$ 的比值, 则设备 U_n 在第 t 次迭代时的传输功率可以表示为 $\delta_n(t)P_{k,\max}$ 。本文假设功率控制变量被划分为 J 个水平, 即 $\delta_n(t) \in \delta = \{1/J, \dots, j/J, \dots, 1\}$ 。

假设信道带宽为 B_k , 则在第 t 次迭代时, 设备 U_n 选择信道 C_k 向网关 G_m 传输数据集的传输速率为:

$$R_{n,m,k}(t) = B_k \log \left(1 + \frac{\delta_n(t) P_{k,\max} g_{n,m,k}(t)}{I_{m,k}(t) + N_0} \right) \quad (1)$$

其中, $g_{n,m,k}(t)$ 表示设备 U_n 选择信道 C_k 向网关 G_m 传输数据集时的信道增益, $I_{m,k}(t)$ 表示通过信道 C_k 向网关 G_m 传输数据集时受到的电磁干扰, N_0 表示噪声功率。

设备 U_n 的数据集传输速率为:

$$R_n(t) = \sum_{m=1}^M \sum_{k=1}^K x_{n,m}(i) z_{n,k}(t) R_{n,m,k}(t) \quad (2)$$

假设在每次迭代中, 样本数据集上传时间为固定值 τ , 则设备 U_n 在第 t 次迭代时可以上传的样本数量 $D_n(t)$ 为:

$$D_n(t) = \left\lfloor \frac{R_n(t) \tau}{\xi} \right\rfloor \quad (3)$$



其中, ξ 为每个样本的数据量大小。

设备 U_n 在第 t 次迭代时选择信道 C_k 传输数据集的传输能耗为:

$$E_{n,k}^{\text{Tx}}(t) = \tau \delta_n(t) P_{k,\max} \quad (4)$$

1.2 边缘模型训练

设备 U_n 对应的数字孪生体下载第 $t-1$ 次迭代后生成的全局模型参数 $\omega_g(t-1)$ 作为第 t 次迭代的边缘模型参数, 即 $\omega_n(t) = \omega_g(t-1)$ 。定义 $s_{n,d}(t)$ 和 $y_{n,d}(t)$ 分别表示样本数据集 $\Pi_n(t)$ 中第 d 个训练样本的输入数据和目标输出数据, 则该训练样本对应的损失函数表述为 $f(\omega_n(t), s_{n,d}(t), y_{n,d}(t))$ 。因此, 样本数据集 $\Pi_n(t)$ 对应的损失函数定义为:

$$F_n(\omega_n(t), t) = \frac{1}{D_n(t)} \sum_{d=1}^{D_n(t)} f(\omega_n(t), s_{n,d}(t), y_{n,d}(t)) \quad (5)$$

损失函数可用于反映边缘模型训练精度。

边缘模型参数采用梯度下降法进行更新, 计算式为:

$$\omega_n(t+1) = \omega_n(t) - \eta \nabla F_n(\omega_n(t), t) \quad (6)$$

其中, $\eta > 0$ 表示学习步长, ∇ 表示梯度运算。

假设网关 G_m 用于训练设备 U_n 的边缘模型的计算资源为 $f_{m,n}(t)$, 样本数据集 $\Pi_n(t)$ 中平均每比特数据在训练时需要的 CPU 周期为 ψ_n , 则训练设备 U_n 的边缘模型所需要的时延和能耗分别为:

$$T_{n,m}^{\text{Tr}}(t) = \frac{\psi_n D_n(t) \xi}{f_{m,n}(t)} \quad (7)$$

$$E_{n,m}^{\text{Tr}}(t) = \varpi f_{m,n}^3(t) T_{n,m}^{\text{Tr}}(t) \quad (8)$$

其中, ϖ 为能耗因子。

在第 t 次迭代时, 用于传输设备 U_n 的样本数据集和训练设备 U_n 的边缘模型所需要的能耗为:

$$E_n(t) = \sum_{k=1}^K z_{n,k}(t) E_{n,k}^{\text{Tx}}(t) + \sum_{m=1}^M x_{n,m}(t) E_{n,m}^{\text{Tr}}(t) \quad (9)$$

用于传输所有设备的样本数据集和进行边缘模型训练的能耗表示为:

$$E(t) = \sum_{n=1}^N E_n(t) \quad (10)$$

1.3 全局模型聚合

在第 t 次迭代时, 网关将所有设备训练后的边缘模型参数传输至集中控制器, 由集中控制器进行全局聚合, 即:

$$\omega_g(t) = \sum_{n=1}^N \frac{D_n(t)}{\sum_{n=1}^N D_n(t)} \omega_n(t) \quad (11)$$

本文采用全局模型损失函数来量化全局模型的精度, 全局模型损失函数表示为:

$$F_g(\omega_g(t), t) = \sum_{n=1}^N \frac{D_n(t)}{\sum_{n=1}^N D_n(t)} F_n(\omega_n(t), t) \quad (12)$$

全局聚合完成后, 集中控制器下发全局模型参数。

2 全局模型损失函数和能耗最小化问题建模

本文基于数字孪生, 通过联合优化大时间尺度的网关选择和小时间尺度的信道分配与功率控制, 解决全局模型损失函数与能耗加权和的最小化问题, 该问题建模为:

$$\begin{aligned} \text{P1: } & \min_{\{x_{n,m}(i), z_{n,k}(t), \delta_n(t)\}} \sum_{t=1}^T [F_g(\omega_g(t), t) + VE(t)] \\ \text{s.t. : } & \text{C1: } x_{n,m}(i) \in \{0, 1\}, \forall U_n \in U, \forall G_m \in G, \forall i \in I_s \\ & \text{C2: } \sum_{m=1}^M x_{n,m}(i) = 1, \forall U_n \in U, \forall i \in I_s \\ & \text{C3: } \sum_{n=1}^N x_{n,m}(i) \leq q_m, \forall G_m \in G, \forall i \in I_s \\ & \text{C4: } z_{n,k}(t) \in \{0, 1\}, \forall U_n \in U, \forall C_k \in C, \forall t \in T_s \\ & \text{C5: } \sum_{k=1}^K z_{n,k}(t) = 1, \forall U_n \in U, \forall t \in T_s \\ & \text{C6: } \sum_{n=1}^N z_{n,k}(t) \leq 1, \forall C_k \in C, \forall t \in T_s \\ & \text{C7: } \delta_n(i) \in \delta, \forall U_n \in U, \forall t \in T_s \end{aligned} \quad (13)$$

其中, V 为能耗权重。C1 表示网关选择变量的取值范围; C2 表示每个设备只能选择 1 个网关传输数据集并进行边缘模型训练; C3 表示每个网关最多可以同时为 q_m 个设备提供边缘模型训练; C4 表示信道分配变量的取值范围; C5 表示每个设备

只能选择 1 条信道传输数据；C6 表示每条信道最多只能接入 1 个设备。C7 表示功率控制变量的取值范围。

3 基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法

本文提出基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法求解 P1。首先，基于升价经验匹配进行大时间尺度的网关选择优化；其次，基于数字孪生提供的状态信息估计，利用数据集感知 UCB 学习小时间尺度的信道分配与功率控制优化。

3.1 基于升价经验匹配的大时间尺度网关选择优化算法

大时间尺度的网关选择问题被转化为一对多匹配问题，并将其定义为 (U, G, L) 。其中 U 和 G 是匹配的参与方，分别表示设备和网关的集合。 L 表示设备对网关的偏好列表集合， $L_n \in L$ 表示设备 U_n 的偏好列表。对于一对多匹配问题 (U, G, L) ，定义基于偏好列表 L 的匹配关系 ϕ ，表示从集合 $U \cup G$ 到集合 $G \cup U$ 的映射。 $\phi(U_n) = G_m$ 且 $\phi(G_m) = U_n$ 表示设备 U_n 与网关 G_m 建立了匹配关系。由于网关配额限制，在每个时段 i 中，设备 U_n 只能与 1 个网关建立匹配关系，而网关 G_m 只能与不超过 q_m 个设备建立匹配关系。

定义经验性能为到第 i 个时段为止，集中控制器所观察到的设备 U_n 选择网关 G_m 的边缘模型损失函数与训练能耗加权和性能的历史平均值。本文通过经验性能构建偏好列表，以网关选择的历史平均性能为依据，解决大时间的网关选择问题，为小时间尺度的信道分配和功率控制提供基础，实现大时间尺度与小时间尺度的解耦。基于升价经验匹配的大时间尺度网关选择优化算法见算法 1，包括基于经验性能的匹配偏好列表构建和基于升价的设备与网关一对多匹配两个过程。

算法 1 基于升价经验匹配的大时间尺度网关选择优化算法

```

输入  $U, G, \{D_n(t)\}, \{F_n(\omega_n(t), t)\}, \{E_n(t)\}, \{q_m\}$ 
输出  $\{x_{n,m}(i)\}$ 
for  $U_n \in U$  do
    遍历所有网关，得到初始偏好值  $\beta_{n,m}(0)$ 
end for
for  $i = 1, 2, \dots, I$  do
    初始化策略变量  $x_{n,m}(i) = 0$ ，网关匹配成本  $p_m(i) = 0$ ，未匹配设备集合  $\Theta = U$ ，向网关  $G_m$  请求匹配的设备集合  $\Gamma_m = \emptyset$ 
    while  $\Theta \neq \emptyset$  do
        for  $U_n \in \Theta$  do
            根据式 (14) 和式 (15) 更新偏好值  $\beta_{n,m}(i)$ 。按偏好值  $\beta_{n,m}(i)$  对网关降序排序，更新偏好列表  $L_n$ 
            设备  $U_n$  根据偏好列表  $L_n$  向网关  $G_m$  发出匹配请求
            网关  $G_m$  将请求匹配的设备  $U_n$  加入  $\Gamma_m$ 
        end for
        for  $G_m \in G$  do
            if  $|\Gamma_m| \leq q_m$  then
                对于  $\forall U_n \in \Gamma_m$ ，令  $x_{n,m}(i) = 1$ ，更新  $\Theta = \Theta \setminus U_n$ 
            else
                将  $\forall U_n \in \Gamma_m$  添加到  $\Theta$ ，并令对应的  $x_{n,m}(i) = 0$ 
                网关  $G_m$  根据式 (16) 升价
            end if
        end for
    end while
end for

```

3.1.1 基于经验性能的匹配偏好列表构建

定义设备 U_n 在第 i 个时段对网关 G_m 的偏好值为 $\beta_{n,m}(i)$ 。首先，设备 U_n 遍历所有的网关并得



到初始偏好值 $\beta_{n,m}(0)$ 。

定义第 i 个时段内设备 U_n 选择网关 G_m 的边缘模型损失函数与训练能耗加权为 $\theta_{n,m}(i)$, 表示为:

$$\theta_{n,m}(i) = \sum_{t=(i-1)T_0+1}^{iT_0} F_n(\omega_n(t), t) + VE_{n,m}^{\text{Tr}}(t) \quad (14)$$

在第 i 个时段开始时, 集中控制器根据截至当前时段的经验性能进行网关选择。因此, 偏好值 $\beta_{n,m}(i)$ 为:

$$\beta_{n,m}(i) = -\frac{\sum_{v=0}^{i-1} x_{n,m}(v) \theta_{n,m}(v)}{\sum_{v=0}^{i-1} x_{n,m}(v)} - p_m(i) \quad (15)$$

其中, 第一项为设备 U_n 选择网关 G_m 的边缘模型损失函数与训练能耗加权和性能的历史平均值, 即经验性能; $p_m(i)$ 是网关的匹配成本, 其初始值为 0。

集中控制器基于偏好值 $\beta_{n,m}(i)$ 对所有网关进行降序排序, 得到设备 U_n 的偏好列表 L_n , 完成基于经验性能的匹配偏好列表构建。

3.1.2 基于升价的设备与网关一对多匹配

基于升价的设备与网关一对多匹配通过提高网关的匹配成本解决设备选择网关的冲突问题, 即若选择某个网关的设备数量大于其配额, 则该网关升价, 迫使部分设备选择其他网关。基于升价的设备与网关一对多匹配过程分为以下 3 个步骤。

步骤 1 初始化。 定义未匹配设备集合为 Θ , 定义向网关 G_m 发出匹配请求的设备集合为 Γ_m 。初始化 $x_{n,m}(i)=0$, $p_m(i)=0$, $\Theta=U$, $\Gamma_m=\emptyset$ 。

步骤 2 更新偏好列表。 设备 U_n 根据当前网关的匹配成本 $p_m(i)$, 用式 (14) 和式 (15) 更新偏好值 $\beta_{n,m}(i)$, 并依据偏好值对网关进行降序排序, 更新偏好列表 L_n 。

步骤 3 升价匹配。 每个未匹配设备 $U_n \in \Theta$ 根据偏好列表 L_n 向网关 G_m 发出匹配请求, 接收到匹配请求的网关 G_m 将对应的设备加入设备集合 Γ_m 。若网关 G_m 接收到的匹配请求数量 $|\Gamma_m| \leq q_m$, 则网关 G_m 接受对应设备的匹配请求, 令 $x_{n,m}(i)=1$, 且将 $U_n \in \Gamma_m$ 移出未匹配设备集合 Θ ,

即更新 $\Theta = \Theta \setminus U_n$ 。若网关 G_m 接收到的匹配请求数量 $|\Gamma_m| > q_m$, 则将设备 $U_n \in \Gamma_m$ 添加到未匹配设备集合 Θ , 令对应的 $x_{n,m}(i)=0$, 同时进行匹配成本的更新, 即网关将自身的匹配成本提高 Δp_m , 表示为:

$$p_m(i) = p_m(i) + \Delta p_m \quad (16)$$

网关 G_m 更新匹配成本后, 重复执行步骤 2 和步骤 3, 直到所有设备完成匹配, 即 $\Theta = \emptyset$ 。

3.2 基于数据集感知 UCB 的小时间尺度信道分配与功率控制优化算法

在大时间尺度网关选择策略基础上, 小时间尺度的信道分配与功率控制优化问题可以建模为多臂赌博机 (multi-armed bandit, MAB) 问题。该模型主要包括决策者、摇臂、动作、奖励 4 个部分。

- 决策者: 决策者为集中控制器, 进行设备的信道分配和功率控制优化。
- 摇臂: 摇臂的集合定义为信道与功率水平的笛卡儿积, 表示为 $A = C \otimes \delta$, 共有 $K \times J$ 个摇臂。摇臂 $A_{k,j} \in A$ 表示信道 C_k 与第 j 个功率水平 j/J 的组合。定义摇臂选择次数为 $Y_{n,k,j}(t)$ 。
- 动作: 定义动作指示变量 $a_{n,k,j}(t)$, $a_{n,k,j}(t)=1$ 表示在第 t 次迭代时集中控制器令设备 U_n 选择摇臂 $A_{k,j}$, 此时 $z_{n,k}(t)=1$, $\delta_n(t)=j/J$ 。
- 奖励: 在第 t 次迭代时, 集中控制器令设备 U_n 选择摇臂 $A_{k,j}$ 的奖励为:

$$r_{n,k,j}(t) = -F_n(\omega_n(t), t) - VE_n(t) \quad (17)$$

UCB 算法是一种求解 MAB 问题的低复杂度算法。作为强化学习中的常用算法之一, UCB 算法基于每次决策后的平均奖励和置信区间^[18]对摇臂的性能进行估计, 并在每次决策中选取置信上界最大的摇臂观察奖励, 以实现探索和利用的权衡。然而, 传统 UCB 算法的探索系数固定不变, 难以根据数据集样本数量的不同权衡探索与利用, 不利于信道分配和功率控制策略的优化。因

此, 本文在探索系数中引入数据集感知, 通过对样本数量的比较, 动态调整探索系数和置信区间, 增强对探索和利用的权衡, 加快算法的收敛。

基于数据集感知 UCB 的小时间尺度信道分配及功率控制算法见算法 2, 包括初始化、决策和学习 3 个步骤。

算法 2 基于数据集感知 UCB 的小时间尺度信道分配与功率控制算法

输入 $U, G, C, \delta, \{P_k^{\max}\}, \{B_k\}, \{g_{n,m,k}(t)\}, \{I_{m,k}(t)\}, \{f_{m,n}(t)\}, \{\psi_n\}, i$

输出 $\{z_{n,k}(t)\}, \{\delta_n(t)\}$

根据大时间尺度网关选择优化算法, 确定设备与网关的匹配关系 $\{x_{n,m}(i)\}$

对 $\forall U_n \in U$, 遍历所有摇臂, 得到初始奖励 $r_{n,k,j}(t)$

for $t=(i-1)T_0+1 \sim iT_0$ do

for $\forall U_n \in U$ do

根据式(18), 式(19)计算置信上界 $r_{n,k,j}^{\text{up}}(t)$

根据式(20)执行动作 $a_{n,k,j}(t)$

集中控制器根据式(17)观察奖励 $r_{n,k,j}(t)$

根据式(21)更新平均奖励 $\bar{r}_{n,k,j}(t+1)$

根据式(22)更新摇臂被执行次数 $Y_{n,k,j}(t+1)$

根据被执行动作 $a_{n,k,j}(t)$ 得到对应的 $z_{n,k}(t)$ 和 $\delta_n(t)$

end for

end for

步骤 1 初始化。首先, 根据基于升价经验匹配的大时间尺度网关选择优化算法, 确定设备与网关的匹配关系 $\{x_{n,m}(i)\}$ 。然后, 对 $\forall U_n \in U$, 遍历所有摇臂并初始化奖励 $r_{n,k,j}(t)$ 和摇臂选择次数 $Y_{n,k,j}(t)$ 。

步骤 2 决策。集中控制器根据第 t 次迭代之前, 设备 U_n 选择摇臂 $A_{k,j}$ 的次数 $Y_{n,k,j}(t)$ 和平均奖励 $\bar{r}_{n,k,j}(t)$ 计算置信上界, 表示为:

$$r_{n,k,j}^{\text{up}}(t) = \bar{r}_{n,k,j}(t) + \theta_n(t) \sqrt{\frac{\ln(t)}{Y_{n,k,j}(t)}} \quad (18)$$

其中, $\theta_n(t)$ 为引入数据集感知后的探索系数, 表达式为:

$$\theta_n(t) = \frac{\sum_{n=1}^N D_n(t-1)}{ND_n(t-1)} \lambda \quad (19)$$

其中, λ 为常数。式(19)表示在第 $t-1$ 次迭代时, 若用于训练设备 U_n 的边缘模型的样本数量小于该次迭代的平均数量, 说明当前选择的摇臂性能较差, 则提高探索系数, 增强对摇臂性能的探索; 反之, 则减小探索系数, 增强对当前探索结果的利用。通过增强对探索和利用的权衡, 提高最优臂的探索速度和利用次数, 加快算法收敛。

在获得置信上界后, 集中控制器选择置信上界最大的摇臂 $A_{k,j}$ 执行动作, 表示为:

$$a_{n,k,j}(t) = \arg \max_A \{r_{n,k,j}^{\text{up}}(t)\} \quad (20)$$

步骤 3 学习。集中控制器观察执行动作后的奖励, 并更新设备 U_n 选择摇臂 $A_{k,j}$ 的次数和平均奖励, 更新式分别为:

$$\bar{r}_{n,k,j}(t+1) = \frac{Y_{n,k,j}(t)\bar{r}_{n,k,j}(t) + a_{n,k,j}(t)r_{n,k,j}(t)}{Y_{n,k,j}(t+1)} \quad (21)$$

$$Y_{n,k,j}(t+1) = Y_{n,k,j}(t) + a_{n,k,j}(t) \quad (22)$$

4 仿真与分析

本文考虑 400 m×40 m 的智能楼宇场景, 共包括 4 个网关、20 个设备和 20 个多模态信道。对于部署于交流配电网的电气设备, 使用 220 V/380 V 低压交流载波信道^[19]; 对于部署于直流配电网的设备, 使用 48 V 低压直流载波信道^[20], 但所提算法同样适用于其他交流载波信道模型和直流载波信道模型。本文采用经典数据集 MINST^[21]对能源调控模型进行训练, 该数据集由 6×10^4 个训练数据和 10^4 个测试样本组成。仿真参数^[22-25]见表 3。

表3 仿真参数^[22-25]

参数	取值
N	20
K_1, K_2, K	8,16,20
J	10
τ	0.1 s
$B_1 \sim B_8$	1 MHz
$B_9 \sim B_{16}$	1 MHz
$B_{17} \sim B_{20}$	16 kHz
$f_{m,n}(t)$	1.8~2.2 GHz
M	4
I, T_0	100,100
q_m	5
N_0	-114 dBm
$P_{1,\max} \sim P_{8,\max}$	0.2 W
$P_{9,\max} \sim P_{16,\max}$	0.1 W
$P_{17,\max} \sim P_{20,\max}$	0.01 W
V	0.5

本文考虑两个对比算法。本文考虑两个对比算法。第一个对比算法为基于UCB的能量感知移动管理^[26] (energy-aware mobility management, EMM) 算法, 将摇臂定义为网关、信道和功率水平的组合, 其优化目标与本文相同, 但无法实现多时间尺度通信资源管理优化; 第二个对比算法为多时间尺度能量调控 (multi-timescale energy regulation, MER) 算法, 优化目标为全局模型损失函数, 大时间尺度优化网关选择, 小时间尺度优化信道分配, 无法实现功率控制与数据集感知。

全局模型损失函数与能耗随权重变化如图2所示。仿真结果表明, 随着权重 V 的增大, 所提算法更加倾向于优化能耗, 使得全局模型损失函数性能下降, 能耗性能提高。可以看出, 所提算法可以通过调整权重 V 的取值来动态权衡全局模型损失函数和能耗性能, 实现两者的动态折中。




图2 全局模型损失函数与能耗随权重变化

全局模型损失函数与能耗加权和随时间平均值随时段变化情况如图3所示。与EMM算法和MER算法相比, 所提算法全局模型损失函数与能耗加权和分别降低了16.77%和39.66%, 且具有较好的收敛性能。这是因为所提算法利用经验性能对全局模型损失函数和能耗最小化问题在多时间尺度进行解耦, 并考虑能耗优化, 具有更好的加权和性能。EMM算法将网关、信道和功率水平的组合设置为摇臂, 优化空间庞大, 导致学习效率低, 算法收敛性差, 难以找到最优组合。MER算法无法实现功率控制和数据集感知, 因此其加权和性能最差, 具体可由图4和图5进一步解释。




图3 全局模型损失函数与能耗加权和随时间平均值随时段变化情况

全局模型损失函数时间平均值和传输能耗时间平均值随时段变化情况分别如图4、图5所示。

相比于 EMM 算法, 所提算法采用多时间尺度通信资源管理优化, 全局模型损失函数和传输能耗分别降低了 21.39% 和 20.94%。相比于 MER 算法, 所提算法全局模型损失函数仅增加了 5.42%, 但传输能耗却降低了 70.05%。这是因为 MER 算法仅考虑全局模型损失函数优化, 采用最大功率传输数据集, 传输能耗性能较差。




图4 全局模型损失函数时间平均值随时段变化情况

收敛性; 另一方面, 基于数字孪生的状态信息估计, 所提算法能够更好地实现全局模型损失函数与能耗加权和优化。EMM 算法的优化空间巨大, 难以学习到最优臂, 因此奖励和最优臂选择比例较低。MER 算法无法实现数据集感知, 无法动态调整探索系数, 且以最大功率传输数据集, 传输能耗大, 奖励最小。




图6 时间平均奖励随迭代变化情况




图5 传输能耗时间平均值随时段变化情况




图7 最优臂选择比例随迭代变化情况

时间平均奖励和最优臂选择比例随迭代变化情况分别如图 6、图 7 所示。仿真结果表明, 截至第 10 000 次迭代, 与 EMM 算法和 MER 算法相比, 所提算法的奖励分别提高了 59.96% 和 40.89%, 最优臂选择比例分别提高了 21.92% 和 5.95%。这是因为一方面, 所提算法考虑了数据集感知, 能够实现探索和利用的权衡, 具有更好的

5 结束语

本文针对智能楼宇多模态通信资源管理问题, 提出基于数字孪生和经验匹配学习的多时间尺度通信资源管理优化算法, 利用数字孪生所提供的状态信息估计, 通过联合优化大时间尺度下的网关选择、小时间尺度下的信道分配和功率控




制, 实现智能楼宇能源调控模型损失函数和能耗加权和最小化。与 EMM 算法和 MER 算法相比, 所提算法的全局模型损失函数和能耗加权和性能分别提升了 16.77% 和 39.66%。本文的研究成果可以为智能楼宇能源调控提供精准模型, 实现多模式通信资源管理与能源调控模型训练的灵活适配, 促进智能楼宇能源调控低碳运行, 为新型电力系统建设提供理论基础。在未来研究中, 将进一步考虑信息新鲜度对能源调控模型的影响。

参考文献:

- [1] 范宏, 于伟南, 柳璐, 等. 双碳目标下考虑电氢互补的智慧园区多楼宇协调调度方法[EB]. 2022.
FAN H, YU W, LIU L, et al. Multi-building coordination scheduling method of smart park considering electric and hydrogen complementation under dual carbon target[EB]. 2022.
- [2] 胡洁, 李培强, 林仕满, 等. 考虑分时电价差异性和基于主从博弈的智能楼宇集群能量共享方法[J]. 电网技术, 2021, 45(12): 4738-4750.
HU J, LI P Q, LIN S M, et al. Considering time-of-use electricity price difference and intelligent building cluster energy sharing method based on master-slave game[J]. Power Grid Technology, 2021, 45(12): 4738-4750.
- [3] 马大燕, 谢祥颖, 那峙雄, 等. 基于调度自动化系统的低压分布式光伏电站接入估算模型[J]. 电信科学, 2020, 36(2): 90-94.
MA D Y, XIE X Y, NA Z X, et al. Dispatch automation system based low voltage distributed photovoltaic power station connected estimation model[J]. Telecommunications Science, 2020, 36(2): 90-94.
- [4] 赵鹏, 蒲天骄, 王新迎, 等. 面向能源互联网数字孪生的电力物联网关键技术及展望[J]. 中国电机工程学报, 2022, 42(2): 447-458.
ZHAO P, PU T J, WANG X Y, et al. Key technologies and prospects of power internet of things for energy internet digital twin[J]. Proceedings of the CSEE, 2022, 42(2): 447-458.
- [5] WU Y, ZHANG K, ZHANG Y. Digital twin networks: a survey[J]. IEEE Internet of Things Journal, 2021, 8(18): 13789-13804.
- [6] 王达, 孙滔, 孙晓文, 等. 数字孪生在网络全生命周期管理中的研究[J]. 电信科学, 2022, 38(4): 138-145.
WANG D, SUN T, SUN X W, et al. Study on digital twins in network lifecycle management[J]. Telecommunications Science, 2022, 38(4): 138-145.
- [7] ZHOU X, XU X, LIANG W, et al. Intelligent small object detection for digital twin in smart manufacturing with industrial cyber-physical systems[J]. IEEE Transactions on Industrial Informatics, 2022, 18(2): 1377-1386.
- [8] 彭跃辉, 韩建沛, 刘念. 考虑需求响应和边缘计算的配电网分布式优化调度[J]. 华北电力大学学报(自然科学版), 2020, 47(4): 19-28.
PENG Y H, HAN J P, LIU N. Distributed optimal scheduling of distribution network considering demand response and edge computing[J]. Journal of North China Electric Power University, 2020, 47(4): 19-28.
- [9] 曾博, 方伟, 徐豪, 等. 基于楼宇分布式能源提升配电网韧性的智能表计优化配置方法[J]. 电网技术, 2021, 45(1): 292-302.
ZENG B, FANG W, XU H, et al. Optimal configuration method of smart meter based on building distributed energy to enhance the toughness of distribution network[J]. Power Grid Technology, 2021, 45(1): 292-302.
- [10] 卢锦玲, 颜禄涵, 腊志源, 等. 基于数字孪生与动态能效模型的综合能源系统实时优化调度策略[EB]. 2022.
LU J L, YAN L H, LA Z Y, et al. Real-time optimal dispatch strategy of integrated energy system based on digital twin and dynamic energy efficiency model[EB]. 2022.
- [11] PAN C, WANG Z, LIAO H, et al. Asynchronous federated deep reinforcement learning-based URLLC-aware computation offloading in space-assisted vehicular networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2022: 1-13.
- [12] MILLS J, HU J, MIM J. Multi-task federated learning for personalized deep neural networks in edge computing[J]. IEEE Transactions on Parallel and Distributed Systems, 2022, 33(3): 630-641.
- [13] 刘姿杉, 程强, 吕博. 面向机器学习的隐私保护关键技术研究综述[J]. 电信科学, 2020, 36(11): 18-27.
LIU Z S, CHENG Q, LYU B. A survey on key technologies of privacy protection for machine learning[J]. Telecommunications Science, 2020, 36(11): 18-27.
- [14] LU Y, HUANG X, ZHANG K, et al. Communication-efficient federated learning and permissioned blockchain for digital twin edge networks[J]. IEEE Internet of Things Journal, 2021, 8(4): 2276-2288.
- [15] SUN W, WANG P, XU N, et al. Dynamic digital twin and distributed incentives for resource allocation in aerial-assisted internet of vehicles[J]. IEEE Internet of Things Journal, 2021 (99): 1-14.
- [16] LIU T, TANG L, WANG W, et al. Resource allocation in DT-assisted internet of vehicles via edge intelligent cooperation[J]. IEEE Internet of Things Journal, 2022, 9(18): 17608 - 17626.
- [17] LU Y, HUANG X, ZHANG K, et al. Low-latency federated learning and blockchain for edge association in digital twin empowered 6G networks[J]. IEEE Transactions on Industrial Informatics, 2021, 17(7): 5098-5107.
- [18] ZHOU Z, LIAO H, ZHAO X, et al. Reliable task offloading for vehicular fog computing under information asymmetry and information uncertainty[J]. IEEE Transactions on Vehicular Technology, 2019, 68(9): 8322-8335.
- [19] 李松浓, 胡晓锐, 郑可, 等. 低压电力线载波通信信道衰减特性测量与分析[J]. 电力系统保护与控制, 2018, 46(4): 99-106.
LI S N, HU X R, ZHENG K, et al. Measurement and research on attenuation characteristics of low voltage power line communication

- channel[J]. Power System Protection and Control, 2018, 46(4): 99-106.
- [20] 祁兵, 王畅, 李彬, 等. 低压直流电力线载波通信系统设计[J]. 智能电网, 2017, 5(8): 822-826.
- QI B, WANG C, LI B, et al. Design of low-voltage DC power line carrier communication system[J]. Smart Grid, 2017, 5(8): 822-826.
- [21] 邱忠宇. 基于动态视觉传感器的目标检测与识别算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
- QIU Z Y. Research on object detection and recognition algorithm based on dynamic vision sensor[D]. Harbin: Harbin Institute of Technology, 2020.
- [22] 周振宇, 王翌, 廖海君, 等. 电力物联网 5G 云-边-端协同框架与资源调度方法[J]. 电网技术, 2022, 46(5): 1641-1651.
- ZHOU Z Y, WANG Z, LIAO H J, et al. 5G cloud-edge-end collaboration framework and resource scheduling method in power internet of things[J]. Power Grid Technology, 2022, 46(5): 1641-1651.
- [23] ZHOU Z, XIONG F, XU C, et al. Energy-efficient vehicular heterogeneous networks for green cities[J]. IEEE Transactions on Industrial Informatics, 2018, 14(4): 1522-1531.
- [24] LIAO H, JIA Z, WANG R, et al. Adaptive learning-based delay-sensitive and secure edge-end collaboration for multi-mode low-carbon power IoT[J]. China Communications, 2022, 19(7): 324-336.
- [25] BAIG S, ASIF H, UMER T, et al. High data rate discrete wavelet transform-based PLC-VLC design for 5G communication systems[J]. IEEE Access, 2018(6): 52490-52499.
- [26] SUN Y, SHENG Z, JIE X. EMM: energy-aware mobility management for mobile edge computing in ultra dense networks[J]. IEEE Journal on Selected Areas in Communications, 2017, 35(11): 2637-2646.

[作者简介]



石理(1984-), 女, 华北电力大学新能源电力系统国家重点实验室博士生, 广州城市理工学院讲师, 主要研究方向为零碳建筑、智能建筑、建筑通信、智能建筑设计理论等。



刘朋矩(1997-), 男, 华北电力大学新能源电力系统国家重点实验室硕士生, 主要研究方向为电力物联网资源分配与网络安全。



杜治钢(1999-), 男, 华北电力大学新能源电力系统国家重点实验室硕士生, 主要研究方向为电力物联网。

张孙恒(1998-), 男, 华北电力大学新能源电力系统国家重点实验室博士生, 主要研究方向为电力物联网资源分配与网络安全。

周振宇(1983-), 男, 华北电力大学新能源电力系统国家重点实验室教授, 主要研究方向为无线通信网络与新技术、物联网与现代传感技术、能源互联网信息通信技术等。

白晖峰(1984-), 男, 博士, 北京智芯微电子科技有限公司高级工程师, 主要研究方向为信息通信、光学互联网等。

何国庆(1981-), 男, 中国电力科学研究院有限公司新能源与储能运行控制国家重点实验室教授级高级工程师, 主要研究方向为新能源并网稳定性分析与控制。

孙文文(1990-), 男, 中国电力科学研究院有限公司新能源与储能运行控制国家重点实验室工程师, 主要研究方向为可再生能源发电及其并网技术。

马跃(1977-), 男, 国网冀北电力有限公司高级工程师, 主要研究方向为电力通信。