

文章编号: 2095-4980(2025)05-0468-08

MEC 协同电力传感网中的计算卸载策略研究

包宇奔, 吴赞红

(广东电网电力调度控制中心, 广东 广州 510000)

摘 要: 随着可再生能源的大规模开发和海量终端的高比例并网, 下一代智能电网中的网络负载将进一步加剧, 这给电力传感网络进行实时数据收集和处理、全域信息监测等带来了前所未有的巨大挑战。同时, 传感器节点存在着能源补充困难和计算资源有限的问题, 传统的网络结构难以满足新一代电网的需求, 因此, 研究如何提高电力传感网络的能量效率具有现实意义。本文提出一种移动边缘计算(MEC)辅助的电力传感网络计算卸载方案, 在计算资源受限的情况下, 对节点的任务处理时延和能耗进行优化, 通过将优化问题建模为马尔可夫决策过程(MDP), 并使用双重 Q 网络(DDQN)算法对问题进行求解, 以最小化系统总开销。仿真结果表明所提出的方案在时延、能耗和收敛性能等方面均优于基准方案。

关键词: 电力传感网络; 能量效率; 移动边缘计算; 计算卸载; 强化学习

中图分类号: TN92

文献标志码: A

DOI: 10.11805/TKYDA2024063

Research on computation off loading strategy in MEC-coordinated power sensor networks

BAO Yuben, WU Zanhong

(Guangdong Power Dispatch and Control Center, Guangzhou Guangdong 510000, China)

Abstract: With the large-scale development of renewable energy and the high proportion of massive terminals connected to the grid, the network load in the next generation smart grid will be further intensified, which brings unprecedented and great challenges to the power sensing network for real-time data collection and processing, and whole-domain information monitoring. At the same time, the sensor nodes have the problems of difficult energy replenishment as well as limited computational resources, and the traditional network structure will be difficult to meet the needs of the next generation grid, so it is of practical significance to study how to improve the energy efficiency of power sensor network. A Mobile Edge Computing(MEC) assisted computing offloading scheme for power sensor network is proposed to optimize the nodes' task processing latency and energy consumption under limited computational resources, by modeling the optimization problem as a Markov Decision Process(MDP) and solving the problem using Double Deep Q Network(DDQN) algorithm to minimize the total system overhead. Simulation results show that the proposed scheme outperforms the benchmark scheme in terms of delay, energy consumption and convergence performance.

Keywords: power sensor network; energy efficiency; Mobile Edge Computing(MEC); computing offloading; reinforcement learning

目前, 新型可再生能源和可控电力设备迅速并入传统电网, 成为未来智能电网的重要组成部分^[1]。随着电力

收稿日期: 2024-01-25; 修回日期: 2024-03-18

基金项目: 南方电网公司科技项目资助(036000KK52220016(GDKJXM20220247))

引用格式: 包宇奔, 吴赞红. MEC 协同电力传感网中的计算卸载策略研究[J]. 太赫兹科学与电子信息学报, 2025, 23(5): 468–475. DOI: 10.11805/TKYDA2024063.

Citation format: BAO Yuben, WU Zanhong. Research on computation off loading strategy in MEC-coordinated power sensor networks[J]. Journal of Terahertz Science and Electronic Information Technology, 2025, 23(5): 468–475. DOI: 10.11805/TKYDA2024063.

终端设备的大规模连接, 电力传感器网络中的业务量逐渐增多, 导致传感器节点(Sensor Nodes, SNs)处理的数据量也在不断增加。同时, 不同业务对节点性能需求不尽相同, 如计算密集型和时延敏感型任务, 这对传统电网的网络结构提出了更高的要求, 也给节点的能耗和计算资源带来了巨大挑战^[2-4]。电力传感网络节点通常用于需要长期监测和数据采集的场景, 如智能电网检测、环境监测、工业生产监控等, 但受部署环境限制、成本考虑、灵活性及安全性要求, 大部分电力传感网络中的节点并不能接入有线电源, 而是采用电池供电, 且电力传感网络节点通常具有有限的计算处理能力和存储容量, 导致它们可能无法实时地处理海量数据或执行复杂的计算任务, 不能满足现阶段电力传感网络中的服务需求^[5]。因此, 提高电力传感网络的能量效率具有重大研究意义^[6-8]。

移动边缘计算(MEC)通过将计算力移动到产生数据的传感器附近, 可在硬件层面满足用户的服务需求^[9-11]。但如何实时高效地将MEC服务器的计算资源分配给多个节点仍是一个亟需解决的问题^[12-13]。经典优化方法如启发式算法^[14-16]、基于规划的方法^[17]等都可用来解决边缘计算的资源分配问题。文献[18]构建了一个可独立可分割的任务模型, 用户设备可选择将部分任务卸载到边缘服务器进行计算, 剩余部分在本地进行计算, 通过联合优化服务器资源调度和任务卸载率并使用近端策略优化算法进行求解, 可有效降低任务处理延迟。文献[19]提出一种移动用户多任务卸载场景, 研究如何对所有用户的卸载决策和通信资源分配进行联合优化, 以最小化用户的能耗与时延, 通过将问题建模为具有二次约束的二次规划问题, 并使用单独的半正定松弛算法处理, 求解二元卸载决策和通信资源最优分配。但随着用户数目的增多和任务数据量的增大, 任务卸载和资源分配问题复杂度呈指数型增长, 以上算法将难以适用。

近年来, 深度强化学习(Deep Reinforcement Learning, DRL)算法成为人工智能领域新的热点, 为解决任务调度和资源分配问题提供了新的思路^[20-21]。文献[22]提出了一种基于深度强化学习的睡眠调度方案, 将部分空闲设备设置为睡眠模式下工作以节省能耗, 并设计了一种针对联合计算和通信资源分配问题的迭代算法来最小化系统能耗。文献[23]设计了一种部分计算卸载方案, 为最大限度地减少任务处理延迟, 每个节点都会优化要卸载到MEC服务器的任务数据量, 同时引入瞬时负载计费机制来调度卸载任务的处理顺序, 以在正确管理服务器负载的同时最大限度地减少任务处理延迟。文献[24]将计算卸载和资源分配联合表述为混合整数非凸优化问题, 通过基于演员-批评者的多智能体强化学习(Multi-Agent Reinforcement Learning, MARL)方案进行求解, 有效减少了系统延迟。文献[25]中引入了非正交多址(Non-Orthogonal Multiple Access, NOMA)技术^[26-27], 研究了NOMA-MEC系统中计算卸载和资源分配问题, 并将该优化问题建模为混合整数规划问题, 通过基于深度强化学习的方法进行求解, 受益于NOMA技术, 频谱效率得到有效提高, 卸载延迟大幅降低, 所提算法能够快速收敛且有效降低总开销。文献[28]中提出了一种基于MEC和云计算协作的计算卸载模型, 在MEC服务器因计算资源不足而无法满足需求的场景下, 有效提高了系统能效, 减少了计算延迟。

上述研究大多基于用户数量固定且任务数据量波动较小的场景, 不能直接用于动态场景, 且随着用户数量的增加, 计算复杂度迅速增长, 上述方案存在收敛困难的问题。尽管众多学者在联合计算卸载和资源分配问题方面已完成了一些优秀的工作, 但上述研究中并未考虑电力传感器网络的场景, 且上述工作对系统的时延和能耗性能提升的程度有限。因此, 本文着力研究MEC辅助的电力传感器网络场景下的计算卸载和资源分配方案。

1 系统模型

1.1 网络模型

图1为一个MEC协同的电力传感网络架构。其中, 基站可同时服务多个传感器节点, 通过在基站中部署MEC服务器的方式, 为网络内所有用户提供计算资源。每个传感器节点可通过无线信道与基站进行通信, 传感器节点的集合可表示为 $\mathcal{N}=\{1, 2, \dots, N\}$ 。另外, MEC服务器的计算资源有限, 在最大可容忍时延的限制下, 可能不足以处理所有来自传感器节点的任务。




Fig.1 Power sensing network architecture for MEC collaboration

图1 MEC协同的电力传感网络架构

1.2 任务模型

假设在某一特定时刻有 n 个传感器节点需要处理本地的计算密集型任务 $R_n=\{D_n, \rho_n, \tau_n\}$, 该计算任务可在本地执行, 也可通过无线信道卸载到MEC进行。其中, D_n 表示执行任务所需的数据量大小, 不同的任务数据量也不相同, 且任务无论是在本地还是在MEC服务器执行, D_n 保持不变; ρ_n 为计算复杂度, 表示执行1 bit的任务所需的计算资源; τ_n 表示任务的最大可容忍时延, 是优化问题中一个很重要的约束条件。

假设来自传感器节点的任务不能再被分割为子任务,即每个传感器节点的任务只能通过本地执行或卸载到 MEC 服务器进行计算。采用 φ_n 表示传感器节点任务的卸载策略,如果节点选择在本地执行其任务,则 $\varphi_n=0$;若选择将任务卸载到 MEC 服务器进行计算,则 $\varphi_n=1$ 。因此,卸载决策向量可定义为 $\boldsymbol{\phi}=[\varphi_1, \varphi_2, \dots, \varphi_n]$ 。如果多个节点同时选择卸载任务到 MEC 服务器进行计算,则无线信道的带宽将会根据任务的数据量大小进行分配。根据香农公式可得节点向基站发送数据的上传速率为:

$$r_n = B \times \frac{D_n}{\sum_{n=1}^N \varphi_n D_n} \log \left(1 + \frac{P_n d_n^{-\zeta} h}{N_0} \right) \quad (1)$$

式中: B 为无线信道带宽; P_n 为节点上传数据时的发射功率; ζ 为路径损耗因子; h 为瑞利信道中的信道增益; d_n 为第 n 个节点与 MEC 服务器之间的距离; N_0 为高斯白噪声的功率谱密度。

1.3 计算模型

1.3.1 本地计算模型

如果节点选择在本地执行任务,则本地的总时延仅包括计算时延,可表示为:

$$T_n^l = \frac{D_n \rho_n}{F_1} \quad (2)$$

式中 F_1 为节点的本地计算资源,且每个节点的计算能力相同。

与总时延相对应地,本地计算的总能耗表达式为:

$$E_n^l = P_n^l T_n^l \quad (3)$$

式中 P_n^l 为本地计算功率。联合总时延和总能耗 2 个指标,本地计算的总加权开销可表示为:

$$C_n^l = W_n^t T_n^l + W_n^e E_n^l \quad (4)$$

式中 W_n^t 和 W_n^e 分别表示传感器节点 n 的计算延迟和能耗的权重参数,不同节点处理任务具有不同的参数设置,满足 $W_n^t + W_n^e = 1, 0 \leq W_n^t \leq 1, 0 \leq W_n^e \leq 1$ 。当节点处理不同类型或不同需求的任务时,如时延敏感型任务,用户可对权重参数进行调整,以满足系统的要求。为简单起见,本文假设任务 R_n 的权重在整个计算卸载过程中保持不变。

1.3.2 计算卸载模型

当节点决定将任务卸载到 MEC 服务器执行时,任务的计算过程可划分为 3 个阶段。在第 1 阶段中,节点需要通过无线信道将任务的输入数据发送给 MEC 服务器,该阶段的时间开销为数据传输时延,可用式(1)计算:

$$T_{n,trans}^o = \frac{D_n}{r_n} \quad (5)$$

式中 r_n 为任务模型中提到的数据在无线信道中的上传速率。对应地,数据传输过程中消耗的能量为:

$$E_{n,trans}^o = P_n T_{n,trans}^o \quad (6)$$

在第 2 阶段,MEC 服务器将根据任务的数据量大小分配计算资源 f_n :

$$f_n = F \times \frac{D_n}{\sum_{n=1}^N \varphi_n D_n} \quad (7)$$

该阶段的时间成本为 MEC 服务器的任务处理时延 $T_{n,com}^o$:

$$T_{n,com}^o = \frac{D_n}{f_n} \quad (8)$$

对于第 2 阶段,当任务在 MEC 服务器执行时,假设节点处于休眠状态且能耗可忽略不计,则第 2 部分的能耗 $E_{n,com}^o$ 为:

$$E_{n,com}^o = P_n^o T_{n,com}^o \quad (9)$$

在第 3 阶段,MEC 服务器将计算结果传给节点,因此该部分的时延是节点下载计算结果所需的时间。由于结果包含的数据量比上传的数据量要小得多,且下载速度非常快,这一部分的时延和能耗可忽略不计。因此,

节点选择卸载计算的总时延和总能耗分别为：

$$T_n^o = T_{n,trans}^o + T_{n,com}^o \quad (10)$$

$$E_n^o = E_{n,trans}^o + E_{n,com}^o \quad (11)$$

联合时延和能耗 2 个指标，卸载计算的总加权开销为：

$$C_n^o = W_n^t T_n^o + W_n^e E_n^o \quad (12)$$

综上所述，整个系统中所有节点的总开销为：

$$C_{all} = \sum_{n=1}^N (1 - \varphi_n) C_n^l + \varphi_n C_n^o \quad (13)$$

2 问题建模

本文将 MEC 辅助的电力传感网络的计算卸载决策表述为一个优化问题，优化目标是联合系统中所有传感器节点的延迟和能耗使总成本最小化。在任务最大可容忍时延和计算能力的约束下，问题可表述为：

$$\begin{cases} \min_{\phi} \sum_{n=1}^N \varphi_n C_n^o + (1 - \varphi_n) C_n^l \\ \text{s.t. } C_1: \varphi_n \in \{0, 1\}, \forall n \in N \\ C_2: (1 - \varphi_n) T_n^l + \varphi_n T_n^o \leq \tau_n, \forall n \in N \end{cases} \quad (14)$$

式中： ϕ 为卸载决策向量； C_l 表示每个节点只能选择通过本地计算或卸载计算执行任务； C_2 保证不管是本地计算还是卸载到 MEC 服务器处理，总时延都要满足用户的最大可容忍时延。

式(14)可通过寻找卸载决策向量的最优值来解决，该决策向量是一个二进制变量。但由于问题的目标函数和可行解是非凸的，因此解决这个由背包问题延伸出的非凸问题是非确定性多项式(Non-deterministic Polynomial, NP)-Hard 问题。不同于传统算法，本文采用深度强化学习的方法来求解问题的最优解 ϕ 。

3 问题求解

3.1 马尔可夫过程

在本节中，上述优化问题被建模为受约束的马尔可夫问题，可用 $\langle \mathcal{S}, \phi, r \rangle$ 表示。整个过程有 3 个关键元素，即状态空间、动作空间和奖励函数，详细描述如下。

1) 状态空间：状态 $\mathcal{S} = [t_c, e_c]$ 由 2 个分量组成，其中 t_c 为系统的总时延， e_c 为系统的总能耗。

2) 动作空间：在整个系统中， ϕ 是包含计算卸载策略 $\varphi_i \in [\varphi_1, \varphi_2, \dots, \varphi_n]$ 的动作空间，且计算策略满足 $\varphi_i \in \{0, 1\}$ 。

3) 奖励函数：对于迭代过程中的每一步，在遍历动作空间中所有可能的动作后，智能体在处于某一状态时都会获得一个奖励，该奖励与目标函数有关。因为优化问题的目标是获得最小的总成本，而强化学习的目的是获得最大的奖励值，因此奖励函数的值与总成本呈负相关关系。为统一数量级，奖励函数可设置为：

$$R = clip\left(\frac{2}{C_{all}} \times 10^{-2}, -10, 200\right) \quad (15)$$

式中 $clip(x, \min, \max)$ 函数用于限制数值的范围， x 为待限制的数值， $\min$ 和 $\max$ 分别为指定的最小值与最大值，由此保证奖励函数的值在区间 $(-10, 200)$ 内，这样设置可加快算法收敛速度。

3.2 基于 DDQN 的解决方案

深度 Q 网络(Deep Q Network, DQN)算法通过神经网络估算状态动作价值，智能体通过与环境的交互得到反馈训练网络参数，并在下一次执行动作时选择能够产生最大价值的动作。DDQN 是 DQN 的改进方法，本文采用 DDQN 算法优化计算卸载策略，其结构如图 2 所示。其中当前值网络基于当前策略与环境进行交互，选择使状态动作价值最大的动作并得到环境给予的奖励，将每一次交互的过程存放到回放记忆单元中。目标值网络提取回放记忆单元中的数据，通过式(16)计算状态动作价值的真实值，其与网络的估计值差的平方为 DDQN 的误差函数，最后通过基于该函数的梯度下降法更新网络参数。当前值网络每隔一段时间从目标值网络中拷贝参数，相较于 DQN，DDQN 分离了动作的选择与价值评估，有效地缓解了 DQN 中的高估问题。




Fig.2 DDQN network structure

图2 DDQN网络结构

$$Y_t^{\text{DDQN}} \equiv R_{t+1} + \gamma Q(\mathbf{S}_{t+1}, \arg \max Q(\mathbf{S}_{t+1}, a; \theta_t^-, \theta_t^-)) \quad (16)$$

式中： γ 为折扣因子； R_{t+1} 为下一个时刻与环境交互得到的奖励； $\mathbf{S}_{t+1}$ 为下一个时刻的状态向量； θ_t 和 θ_t^- 分别为当前网络和目标网络的参数； $\arg \max$ 表示选择潜在奖励最大的动作。

由于DDQN算法每次选择动作的根据是当前网络的参数，而不是目标网络的参数，因此计算目标值时偏小，这有效避免了DQN算法 Q 值过估计的问题。DDQN算法的详细流程见算法1。

算法1 DDQN算法

算法输入：迭代轮数 T ，状态特征维度 n ，动作集 A ，步长 a ，衰减因子 γ ，探索率 ε ，当前网络 Q ，目标网络 Q' ，批量梯度下降的样本数 m ，目标网络参数更新频率 C 。

算法输出：网络参数

- 1) 初始化当前网络的参数 θ 和目标网络的参数 θ^- ，清空记忆池大小 D 。
- 2) 从1到 T 进行整数迭代
 - a) 初始化 S 得到特征向量 $\phi(S)$
 - b) 在网络中使用 $\phi(S)$ 作为输入，得到动作对应的 Q 值输出。用 ε -贪婪算法在当前 Q 值输出中选择对应的动作 A ；
 - c) 在状态 S 执行当前动作 A ，得到新状态 S' 对应的特征向量 $\phi(S')$ 、奖励 r 和是否终止状态 is_end ；
 - d) 将 $R\{\phi(S), A, r, \phi(S'), is_end\}$ 存入经验回放集合 D ；
 - e) 令 $S=S'$
 - f) 从经验回放集合 D 中随机采样 m 个样本 $\{\phi(S_j), A_j, R_j, \phi(S'_j), is_end_j\}, j=1, 2, \dots, m$ ，计算当前目标值 Y_j ：

$$Y_j = \begin{cases} R_j \\ R_j + \gamma Q'(\phi(S'_j), \arg \max Q(\phi(S'_j), a; \theta_t), \theta_t^-) \end{cases};$$
 - g) 使用均方差损失函数 $\frac{1}{m} \sum_{j=1}^m (Y_j - Q(\phi(S_j), A_j, \theta))^2$ ，通过神经网络的梯度反向传播更新当前网络的所有参数 θ ；
 - h) 如果迭代次数 $\%C=1$ ，则更新目标网络参数 $\theta^- = \theta$ ；
 - i) 若 S' 是终止状态，当前轮迭代完毕；否则，转到步骤b)。

4 仿真结果

为验证所提出的基于DDQN算法的计算卸载方案在电力传感器网络场景下的有效性和优越性，将该方案与其他3种基准方案进行比较：全本地计算方案，即所有的传感器节点都在本地执行任务；全卸载方案，即所有的传感器节点都将任务卸载到MEC服务器执行；基于DQN算法的计算卸载方案，即基于DQN算法的计算卸载策

略。选取系统时延和能耗的加权和作为评价指标，分析不同参数设置下各种方案的性能表现。仿真参数的设置详见表 1。

为验证 DDQN 算法的收敛性能，本文在用户数为 6，任务量大小随机取自[1,5] KB 的场景下进行实验。实验中考察了不同学习率(R)和折扣因子(γ)的组合。其中，学习率是控制新样本信息更新旧样本信息比例的参数，通常取较小值以确保学习过程的稳定性和收敛性；折扣因子决定了未来奖励对当前行为的影响程度。在实验中，本文参考文献[29]中的 DDQN 算法参数设置，观察 DDQN 算法在不同 R 和 γ 组合下累积奖励值随迭代次数的变化。结果如图 3 所示，所有曲线在大约 300 次迭代后达到了收敛状态。在 $R=0.000\ 1$ ， $\gamma=0.99$ 时，DDQN 算法获得了最大的累积奖励值。




Fig.3 Convergence performance of DDQN under different parameters
图3 DDQN 在不同参数下的收敛性能

表1 仿真参数 Table1 Simulation parameters	
parameter	value
channel bandwidth B/MHz	5
path loss exponent ζ	-2.812 5
Gaussian white noise power spectral density $N_0/(\text{W}\cdot\text{Hz}^{-1})$	10^{-13}
transmission rate of the sensor node P_n/mW	100
local computing power of the sensor node F/GHz	1
maximum tolerable delay τ/s	0.25
offloaded task data volume D_n/KB	[1,5]
edge server computing capacity F/GHz	8
distance from the sensor node to the base station d/m	300
weight factor of delay and energy consumption	0.5




Fig.4 Comparison of convergence performance between DDQN algorithm and DQN algorithm
图4 DDQN 与 DQN 收敛性能对比

为验证 DDQN 算法和 DQN 算法的收敛性能，本文在用户数为 5，任务量大小随机取自[1,5] KB 的场景下进行对比实验。图 4 显示出了 DDQN 算法的累积奖励值在达到稳定状态后，明显高于 DQN 算法。表明 DDQN 算法通过使用双重网络结构，有效解决了 Q 值过度估计的问题，提高了策略的质量。此外，图中的阴影区域表示了两种算法在 1 000 次迭代中的奖励值的波动范围，DDQN 算法的波动范围较小，且累积奖励值较高，表明 DDQN 算法能够更稳定地选择更优的动作，具有更好的性能。




Fig.5 Average total system overhead of each algorithm in scenarios with different task data volumes
图5 不同任务数据量场景下各算法的平均系统总开销




Fig.6 Total cost of each algorithm system in scenarios with different numbers of nodes
图6 不同节点数目场景下各算法系统总开销

为评估各种计算卸载策略在不同任务数据量下的性能，本文在节点数目固定为 8 的场景下，对比了几种不同策略的平均系统总开销。图 5 显示了在任务数据量从[1,5] KB 到[20,25] KB 变化时，各种策略的平均系统总开销都呈现出上升的趋势，但基于 DDQN 算法的策略在所有数据量下，都保持最低的平均系统总开销，证明了

DDQN 算法能够有效地优化计算卸载策略,降低系统的时延和能耗。

为评估各种计算卸载策略在不同节点数目下的性能,本文在任务数据量固定为[1,5] KB 的场景下,对比了几种不同策略的平均系统总开销。如图 6 所示,当节点数在 4~9 变化时,所有策略的系统总开销都呈现出上升的趋势。但基于 DDQN 算法的策略在所有节点数目下,都能够保持最低的系统总开销,证明了 DDQN 算法能够有效地优化计算卸载策略,减少系统的时延和能耗。

5 结论

本文针对 MEC 协同电力传感网络中节点任务的计算卸载场景,研究了在满足节点最大可容忍时延的约束条件下,对任务调度和资源分配策略进行优化的问题,其目标是最小化系统的总时延和总能耗。首先,本文分析了电力传感网络的特点和需求,以及 MEC 协同的优势和挑战。然后将优化问题建模为马尔可夫决策过程,并提出了一种基于 DDQN 算法的计算卸载策略求解方案。该方案能够根据网络状态和节点特征,动态地决定每个节点的计算卸载策略,从而实现系统的全局优化。最后,通过仿真实验和数值分析,验证了与其他基准算法相比,该方案能够显著降低系统的时延和能耗,同时具有更好的稳定性和收敛性。未来的工作将主要研究在多 MEC 服务器协作以及海量可控终端接入的场景下,如何进一步提高系统的性能和效率。

参考文献:

- [1] CAO Zijian, LIN Jin, WAN Can, et al. Optimal cloud computing resource allocation for demand side management in smart grid[J]. *IEEE Transactions on Smart Grid*, 2016, 8(4):1943–1955. DOI:10.1109/TSG.2015.2512712.
- [2] ELHABYAN R, SHI W, ST-HILAIRE M. Coverage protocols for wireless sensor networks: review and future directions[J]. *Journal of Communications and Networks*, 2019, 21(1):45–60. DOI:10.1109/JCN.2019.000005.
- [3] SRIVASTAVA A, MISHRA P K. A survey on WSN issues with its heuristics and meta-heuristics solutions[J]. *Wireless Personal Communications*, 2021, 121(1):745–814. DOI:10.1007/s11277-021-08659-x.
- [4] TRIPATHI A, GUPTA H P, DUTTA T, et al. Coverage and connectivity in WSNs: a survey, research issues and challenges[J]. *IEEE Access*, 2018(6):26971–26992. DOI:10.1109/ACCESS.2018.2833632.
- [5] FEI Zesong, LI Bin, YANG Shaoshi, et al. A survey of multi-objective optimization in wireless sensor networks: metrics, algorithms, and open problems[J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(1): 550–586. DOI: 10.1109/COMST.2016.2610578.
- [6] GUO Songtao, LIU Jiadi, YANG Yuanyuan, et al. Energy-efficient dynamic computation offloading and cooperative task scheduling in mobile cloud computing[J]. *IEEE Transactions on Mobile Computing*, 2019, 18(2):319–333. DOI:10.1109/TMC.2018.2831230.
- [7] LI Y Z, YU C F, SHAHIDEHPOUR M, et al. Deep reinforcement learning for smart grid operations: algorithms, applications, and prospects[J]. *Proceedings of the IEEE*, 2023, 111(9):1055–1096. DOI:10.1109/JPROC.2023.3303358.
- [8] GAO Mingjin, LI Jun, JAYAKODY D N K, et al. A super base station architecture for future ultra-dense cellular networks: toward low latency and high energy efficiency[J]. *IEEE Communications Magazine*, 2018, 56(6): 35–41. DOI: 10.1109/MCOM.2018.1700414.
- [9] SPINELLI F, MANCUSO V. Toward enabled industrial verticals in 5G: a survey on MEC-based approaches to provisioning and flexibility[J]. *IEEE Communications Surveys & Tutorials*, 2021, 23(1):596–630. DOI:10.1109/COMST.2020.3037674.
- [10] MEHRABI M, YOU D, LATZKO V, et al. Device-enhanced MEC: Multi-access Edge Computing(MEC) aided by end device computation and caching: a survey[J]. *IEEE Access*, 2019(7):166079–166108. DOI:10.1109/ACCESS.2019.2953172.
- [11] SANTOS Á, BERNARDINO J, CORREIA N. Automated application deployment on multi-access edge computing: a survey[J]. *IEEE Access*, 2023(11):89393–89408. DOI:10.1109/ACCESS.2023.3307023.
- [12] NENCIONI G, GARROPPO R G, OLIMID R F. 5G Multi-access Edge Computing: a survey on security, dependability, and performance[J]. *IEEE Access*, 2023(11):63496–63533. DOI:10.1109/ACCESS.2023.3288334.
- [13] LI Qian, SHI Liqin, ZHANG Zhongjun, et al. Resource allocation in UAV-enabled wireless-powered MEC networks with hybrid passive and active communications[J]. *IEEE Internet of Things Journal*, 2023, 10(3): 2574–2588. DOI: 10.1109/JIOT.2022.3214539.
- [14] DONG S, XIA Y J, KAMRUZZAMAN J. Quantum particle swarm optimization for task offloading in mobile edge computing[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(8):9113–9122. DOI:10.1109/TII.2022.3225313.

- [15] YUAN Xiaoming, TIAN Hansen, ZHANG Wenshuo, et al. CA-PSO: a combinatorial auction and improved particle swarm optimization based computation offloading approach for E-healthcare[C]// ICC 2022—IEEE International Conference on Communications. Seoul, Korea: IEEE, 2022: 3850–3855. DOI: 10.1109/ICC45855.2022.9838733.
- [16] BI Jing, YUAN Haitao, DUANMU Shuaifei, et al. Energy-optimized partial computation offloading in mobile-edge computing with genetic simulated-annealing-based particle swarm optimization[J]. IEEE Internet of Things Journal, 2021, 8(5): 3774–3785. DOI: 10.1109/JIOT.2020.3024223.
- [17] LEI Lei, XU Huijuan, XIONG Xiong, et al. Joint computation offloading and multiuser scheduling using approximate dynamic programming in NB-IoT edge computing system[J]. IEEE Internet of Things Journal, 2019, 6(3): 5345–5362. DOI: 10.1109/JIOT.2019.2900550.
- [18] ZHANG Xiayan, WANG Junxuan, WANG Bing, et al. Off loading strategy for UAV-assisted mobile edge computing based on reinforcement learning[C]// 2022 IEEE International Conference on Communications in China (ICCC). Sanshui, Foshan, China: IEEE, 2022: 702–707. DOI: 10.1109/ICCC55456.2022.9880697.
- [19] 孟敏. 基于二次规划的任务卸载决策和资源分配方法[J]. 太赫兹科学与电子信息学报, 2018, 16(6): 1080–1086, 1104. (MENG Min. Research on task offloading decision and resource allocation method based on quadratic programming[J]. Journal of Terahertz Science and Electronic Information Technology, 2018, 16(6): 1080–1086, 1104.) DOI: 10.11805/TKYDA201806.1080.
- [20] ZAIMEN K, BRAHMIA M E A, MOALIC L, et al. A survey of artificial intelligence based WSNs deployment techniques and related objectives modeling[J]. IEEE Access, 2022(10): 113294–113329. DOI: 10.1109/ACCESS.2022.3217200.
- [21] OSAMY W, KHEDR A M, SALIM A, et al. Coverage, deployment and localization challenges in wireless sensor networks based on artificial intelligence techniques: a review[J]. IEEE Access, 2022(10): 30232–30257. DOI: 10.1109/ACCESS.2022.3156729.
- [22] ZHU Nengyu, XU Xiaodong, HAN Shujun, et al. Sleep-scheduling and joint computation-communication resource allocation in MEC networks for 5G IoT[C]// 2021 IEEE Wireless Communications and Networking Conference (WCNC). Nanjing, China: IEEE, 2021: 1–7. DOI: 10.1109/WCNC49053.2021.9417322.
- [23] GUO Songtao, LIU Jiadi, YANG Yuanyuan, et al. Energy-efficient dynamic computation offloading and cooperative task scheduling in mobile cloud computing[J]. IEEE Transactions on Mobile Computing, 2019, 18(2): 319–333. DOI: 10.1109/TMC.2018.2831230.
- [24] GARAALI R, CHAIEB C, AJIB W, et al. Learning-based task offloading for mobile edge computing[C]// 2022 IEEE International Conference on Communications. Seoul, Korea: IEEE, 2022: 1659–1664. DOI: 10.1109/ICC45855.2022.9838831.
- [25] SHANG Ce, SUN Yan, LUO Hong, et al. Computation offloading and resource allocation in NOMA-MEC: a deep reinforcement learning approach[J]. IEEE Internet of Things Journal, 2023, 10(17): 15464–15476. DOI: 10.1109/JIOT.2023.3264206.
- [26] DAI Linglong, WANG Bichai, DING Zhiguo, et al. A survey of non-orthogonal multiple access for 5G[J]. IEEE Communications Surveys & Tutorials, 2018, 20(3): 2294–2323. DOI: 10.1109/COMST.2018.2835558.
- [27] VAEZI M, SCHÖBER R, DING Zhiguo, et al. Non-orthogonal multiple access: common myths and critical questions[J]. IEEE Wireless Communications, 2019, 26(5): 174–180. DOI: 10.1109/MWC.2019.1800598.
- [28] ZHAO Junhui, LI Qiuping, GONG Yi, et al. Computation offloading and resource allocation for cloud assisted mobile edge computing in vehicular networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7944–7956. DOI: 10.1109/TVT.2019.2917890.
- [29] HASSELT H V, GUEZ A, SILVER D. Deep reinforcement learning with double Q-learning[C]// Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix, Arizona: AAAI Press, 2016: 2094–2100. DOI: 10.5555/3016100.3016191.

作者简介：

包宇奔(1994–)，男，硕士，工程师，主要研究方向为电力通信、光传输网、光纤传感。email: 594168205@qq.com.

吴赞红(1973–)，男，硕士，高级工程师，主要研究方向为电力通信、光网络传输技术等。