

基于 WPT-MEC 的动态自适应卸载方法

苏麟¹, 党小超^{1,2}, 郝占军^{1,2}, 汝春瑞¹, 尚旭¹

(1. 西北师范大学计算机科学与工程学院, 甘肃 兰州 730070; 2. 甘肃省物联网工程研究中心, 甘肃 兰州 730070)

摘要: 针对动态衰落时变的信道状态信息, 为解决多用户的任务卸载和资源优化问题, 将无线电能传输 (WPT, wireless power transmission) 技术和移动边缘计算 (MEC, mobile edge computing) 结合, 提出一种基于 WPT-MEC 的动态自适应卸载 (RLDO) 方法。无线电能传输技术可为无线终端用户 (WEU, wireless end-user) 提供能量, 有效缓解传统电池供能有限的问题。为使资源利用最大化, 设计一个无线电能的 MEC 网络模型, 无线终端用户从无线接入点 (AP, access point) 收集的能量存储至可充电电池内, 再利用此能量进行任务计算或任务卸载。该方法通过部署在 MEC 服务器的全连接深度神经网络 (DNN, deep neural network) 进行实时的卸载决策。采用完全的二元制卸载策略进行卸载决策。仿真结果表明, 在面向多用户时变的无线信道环境下, 该方法的计算速率仍可以保持在 92% 以上。与基本方法相比, 在提高计算速率、降低时延和能耗方面具有较大优越性, 有效降低了计算复杂度。

关键词: 信道状态信息; 移动边缘计算; 无线电能传输; 深度神经网络; 动态自适应卸载

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2022.00291

Dynamic adaptive offloading method based on WPT-MEC

SU Lin¹, DANG Xiaochao^{1,2}, HAO Zhanjun^{1,2}, RU Chunrui¹, SHANG Xu¹

1. College of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China

2. Gansu Province Internet of Things Engineering Research Center, Lanzhou 730070, China

Abstract: For the dynamic fading time-varying channel state information, a dynamic adaptive offloading (RLDO) method based on WPT-MEC was proposed to solve the task offloading and resource optimization problems for multiple users by combining wireless power transmission (WPT) technology and mobile edge computing (MEC). The wireless power transmission technology can provide energy to wireless end-user (WEU) and effectively alleviate the problem of limited energy supply from conventional batteries. To maximize the resource utilization, a wireless powered MEC network model was designed where the energy collected by the wireless end-user from the wireless access point (AP) was stored in a rechargeable battery, and then this energy was used for task computation or task offloading. The approach performed real-time offloading decisions through a fully connected deep neural networks (DNN) deployed in the MEC server. A fully binary offloading strategy was used for the offloading decision. Simulation results show that the computation rate of the method can still be maintained above 92% in a multi-user time-varying wireless channel-oriented environment. Compared with the basic method, it has great advantages in improving the calculation rate, reducing the delay and energy consumption, and effectively reduces computational complexity.

Key words: channel state information, mobile edge computing, wireless power transmission, deep neural network, dynamic adaptive offloading

收稿日期: 2022-05-24 ; 修回日期: 2022-08-04

通信作者: 党小超, dangxc@nwnu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62162056); 甘肃省产业支撑计划项目 (No.2021CYZC-06)

Foundation Items: The National Natural Science Foundation of China (No.62162056), The Industrial Support Foundations of Gansu (No.2021CYZC-06)

0 引言

随着物联网技术的迅猛发展^[1], 智能终端用户对计算的要求越来越高, 如低时延、低能耗的计算密集型任务^[2]。云计算在无线电接入网络中靠近这些移动设备的地方提供计算能力^[3-4], 虽然云中心有很强的计算能力, 终端用户可以将任务卸载至传统的云中心进行处理, 但云中心的低带宽和高时延无法满足用户实时性的需求。移动边缘计算 (MEC, mobile edge computing) 则是一种改进卸载效率的折中方法^[5-8], 可以有效缓解云端处理庞大数据的压力。相较于云中心, MEC 服务器距数据源更近, 数据存储和计算可以在 MEC 服务器上进行, 保证任务处理的实时性, 为终端用户提供更智能的服务。由于 MEC 服务器的资源有限, 结合无线电能传输 (WPT, wireless power transmission) 技术和移动边缘计算成为一种提高低功耗无线传感器设备和可穿戴设备网络数据处理能力的有效方法^[9]。

无线电能传输技术对缓解无线终端用户有限的使用寿命起到关键作用。与传统的依靠电池或可充电电池相比, 无线电能的 MEC 网络不仅在理论上为无线终端设备提供更长的使用寿命, 还能有效地满足终端用户的实时性需求^[10]。无线电能技术主要有磁 (场) 耦合式、电 (场) 耦合式或 Radio Frequency-enabled wireless energy transfer (WET) 技术等^[11-13]。文献[14]在网络需求、系统架构和资源管理等方面提出一个无线电能的 MEC 工业互联网系统。为了最大化所有终端物联网设备的总计算速度, 同时满足终端设备的能量需求, 文献[15]提出了一个无人机携带无线电能的移动边缘计算系统, MEC 服务器可为物联网设备提供能源和有限的计算资源。文献[16]研究了点对点的 MEC 系统, 终端设备的计算卸载或本地计算由无线接入点提供电源, 通过数学框架来描述成功计算的概率。文献[17]基于 MEC-WPT 模型, 研究最大化收集能量和最小化执行计算任务的能量消耗方案, 延长终端用户的使用时间。将剩余能量的最大化问题视为一个非凸的优化问题, 并结合凸优化方法和增广拉格朗日乘数法解决此问题。

为缓解庞大数据量对云端的压力, MEC 的卸载问题逐渐得到广泛关注, 文献[18]考虑任务卸载时产生的卸载成本以及卸载效率问题, 忽略了终端设备本身所具有的计算能力。文献[19]研究了 MEC 中

的任务卸载和资源调度问题, 提出一种面向多用户的联合计算卸载和任务调度方案。文献[20]联合考虑了无人机辅助系统中的计算卸载、资源分配和飞行轨迹调度, 达到最小化平均能耗的目的。文献[21]在海洋物联网的环境下, 权衡时延和能耗, 设计卸载优化问题, 并提出一种两阶段联合的优化卸载策略, 可以在时延敏感的条件下进行优化计算和资源分配。文献[22]提出一种在 MEC 环境下的任务卸载和资源分配方法, 采用深度强化学习方法为移动用户选择合适的任务计算节点, 实验结果表明, 所提方法可以降低执行任务产生的平均时延和系统的能量消耗。上述文献针对任务卸载和资源调度等方面进行了研究, 但是在 MEC 系统中处理任务时无法更好地适应信道状态信息的时变性。

为实现 MEC 卸载能耗的最小化和资源分配的合理化, 很多研究者提出 WPT 与 MEC 结合的办法。文献[23]通过考虑无线电能的多用户 MEC 系统, 提出一种基于 WPT-MEC 的最优资源分配方案, 使无线接入点的总能量消耗最小化, 但是取决于用户的个人计算时延约束。文献[24]为解决最小化卸载成本的问题, 提出了一种基于深度 Q 网络的 MEC 任务卸载和资源分配方法。文献[25]在文献[23-24]的基础上为快速解决在信道相干时间内的组合优化问题, 设计了一个无线电能的 MEC 网络, 提出一种基于深度强化学习的 MEC 在线卸载方法。文献[26]研究了在物联网系统下, 在 WPT-MEC 模型中引入反向散射辅助技术, 有效减少通信所需的功率, 通过联合优化传输功率和反向散射系数实现最大化的计算速率。

上述文献从不同的角度研究了 MEC 的计算卸载问题, 将深度强化学习的方法应用于解决任务卸载的问题^[27-29], 但既考虑多用户的本地计算能力, 又考虑面对动态衰落的无线信道状态环境的研究相对较少。与上述研究不同之处在于, 为更好地完成计算卸载和合理化的分配资源, 本文提出一种基于 WPT-MEC 动态在线自适应卸载 (RLDO) 方法, 该方法利用部署在 MEC 服务器上全连接的深度神经网络进行卸载决策, 在动态衰落的无线信道状态下可以自适应地输出最优卸载动作, 为减少训练代价, 采用经验回放技术和保序量化的方法。设计 WPT-MEC 模型, 无线接入点上稳定的电源可以向无线终端用户提供能量, 通过联合优化系统的各个资源, 保证用户在规定时间内收集的能量可以完成

本地任务计算或完成将任务数据上传至 MEC 服务器的各种能量需求。卸载决策采取完全的二元制卸载策略。仿真结果表明, 本文所提方法在提高计算速率、降低时延和能耗方面具有较好的优越性。

1 系统模型

一个带有 MEC 服务器的无线接入点 (AP, access point) 和 N 个无线终端用户 (WEU, wireless end-user) 组成一个无线电能 MEC 网络, 用 $N = \{1, 2, 3, \dots, i, \dots, N\}$ 表示用户集, 用户与 MEC 服务器之间通过无线网络通信。参见文献[30], 假设 AP 上稳定的电源, 可以向 WEU 发送射频能量, 每个 WEU 上都装有一块可充电电池, 可以存储来自 AP 的能量, 用来执行本地任务和上传任务数据。本文假设此系统上行链路的计算卸载和下行链路的 WPT 在相同的无线频段上进行。为避免相同频段无线信号之间的相互干扰, 本文采取时分多址的技术, 将系统的总时间定为 T 。因此, 本文整个传输过程大致分为 3 个部分, 分别是 WEU 收集 AP 发送的能量、任务卸载决策阶段和任务计算阶段。系统模型如图 1 所示。

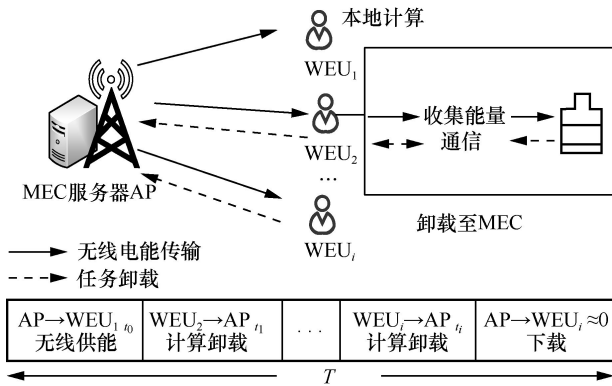


图 1 系统模型

系统的总时间 T 被分为 t_0, t_1, \dots, t_i 等长的时间段, t_0 时间段表示 WEU 从 AP 获取能量, t_1, \dots, t_i 时间段表示用户进行本地计算或计算卸载, 根据仿真实验结果, MEC 服务器将计算结果传回 WEU 的数据量过小, 因此忽略此段下载所需要的时间, 令下载时间为 0。每个 WEU 从 AP 获得能量的多少和通信速度与信道增益有关, MEC 服务器与无线终端用户的信道增益用 g_i 表示。WEU 通过从 AP 获取射频信号, 再将其转化为能量存储到自身的可充电电池内, 以保证每个 WEU 在本地计算和需要将计算

任务卸载至 MEC 服务器时的能量消耗。令 $\partial \in (0, 1)$ 表示能量转化率, P_i 表示 AP 所发送的射频功率。第 i 个 WEU 在系统时间 t_0 内从 AP 收集存储的能量可表示为

$$E_i = \partial P_i g_i t_0, \forall i \in N \quad (1)$$

对于信道增益 g_i , 由于信号进行多径传播达到接收点处的场强来自不同传播的路径, 在无线通信的信道环境中, 电磁波经过反射、折射、散射等多条路径传播到达终端用户接收机后, 总信号的强度服从瑞利分布。在衰落的信道状态下用自由空间路径损耗模型乘瑞利分布模型得到信道增益

$$g_i = G_d \left(\frac{3 \times 10^8}{4\pi f_c l_i} \right)^{P_i} \quad (2)$$

其中, G_d 为天线增益, f_c 表示载波频率, l_i 表示发送端与接收端的距离, P_i 表示路径衰减指数。

1.1 卸载模型

每个 WEU 都会产生多个独立执行的任务, 根据完全的二元制卸载决策, 此时计算任务可以选在本地执行, 也可以将任务全部卸载至 MEC 服务器进行计算, 计算卸载基本流程如图 2 所示。

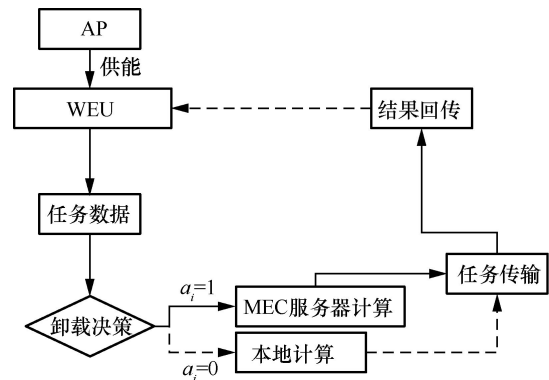


图 2 计算卸载基本流程

WEU 产生的计算任务可表示为 $D_i = (c_i, T_{\max}, d_i, a_i)$, c_i 表示完成计算任务所需要的周期, T_{\max} 表示系统允许的最大时延, d_i 表示 WEU 所产生的数据量, a_i 表示第 i 个 WEU 计算任务的卸载决策情况, 卸载决策参数 $a = \{a_1, a_2, \dots, a_i, \dots, a_N\}$ 。当 $a_i = 0$ 表示计算任务在本地执行, 若 $a_i = 1$ 表示计算任务卸载至 MEC 服务器计算。

1.2 本地计算模式

当 $a_i = 0$ 时, WEU 产生的计算任务选择本地计

算。令 $f_{1,i}$ 表示 WEU 本地处理器的计算能力, 则第 i 个 WEU 本地计算任务产生时延为

$$t_{1,i} = \frac{c_i}{f_{1,i}}, \quad t_{1,i} \in [0, T_{\max}] \quad (3)$$

在 $t_{1,i}$ 时间内, 用 $kf_{1,i}^3$ 表示本地计算的损耗效率, 则第 i 个 WEU 在本地计算所产生的能耗 $E_{1,i}$ 表示为

$$E_{1,i} = kf_{1,i}^3 t_{1,i}, E_{1,i} \leq E_i \quad (4)$$

参见文献[31], 其中 $k = 10^{-26}$, k 表示计算能量效率的系数, 其大小取决于无线设备的芯片结构。

WEU 在本地执行任务产生一部分能耗, 应不大于在规定时间内所收集的能量, 因此, WEU 电池内剩余的能量可表示为

$$E_{\text{res}} = E_i - E_{1,i} \quad (5)$$

为在时间 T 内可以最大化地处理数据, 令 $E_{1,i} = E_i$, 用户处理的比特数为 $t_{1,i} f_{1,i} / \theta$, $\theta > 0$ 表示处理 1 bit 任务数据所需要的周期数, 则第 i 个 WEU 进行本地计算的速率为

$$R_{1,i} = \frac{t_{1,i} f_{1,i}}{\theta T_{\max}} \quad (6)$$

由式(4)得出 $f_{1,i}$ 可表示为

$$f_{1,i} = \left(\frac{E_{1,i}}{kt_{1,i}} \right)^{1/3} = \left(\frac{E_i}{kt_{1,i}} \right)^{1/3} \quad (7)$$

由式(1)最终化简可得第 i 个 WEU 本地计算的速率, 表示为

$$R_{1,i} = \frac{\partial (P_i g_i t_0)^{1/3} t_{1,i}^{2/3}}{k\theta T_{\max}}, P_i > 0, g_i > 0 \quad (8)$$

1.3 MEC 模式

当 $a_i = 1$ 时, WEU 将计算任务卸载至 MEC 服务器上执行, 在无线信道内 WEU 的数据上传速度表示为 r_i , 令 $f_{M,i}$ 表示 MEC 服务器的计算能力。

MEC 产生的时延由 WEU 将数据传到 MEC 服务器的传输时间、在 MEC 服务器执行任务的处理时间以及将处理好的数据结果传回用户的时延 3 个部分组成, 假设 MEC 服务器下传至 WEU 的时间约为 0, 可忽略不计。则第 i 个 WEU 在 MEC 模式的传输时延为

$$t_{M,i}^{\text{tran}} = \frac{d_i}{r_i} \quad (9)$$

在 MEC 服务器执行任务的处理时间可表示为

$$t_{M,i}^{\text{com}} = \frac{c_i}{f_{M,i}} \quad (10)$$

综上分析, 第 i 个 WEU 产生的计算任务卸载至 MEC 服务器处理的总时延为

$$t_{M,i} = \frac{c_i}{f_{M,i}} + \frac{d_i}{r_i}, t_{M,i} \in [0, T_{\max}] \quad (11)$$

在 $t_{M,i}$ 时间内, MEC 服务器所产生的能耗由 MEC 服务器执行计算任务产生的能量消耗以及 WEU 上传卸载数据产生的能量消耗两部分组成, 则第 i 个 WEU 完成计算卸载任务所产生的能耗为

$$E_{M,i} = kf_{M,i}^3 \frac{c_i}{f_{M,i}} + \frac{d_i}{r_i} P_i^M = kf_{M,i}^2 c_i + \frac{d_i}{r_i} P_i^M \quad (12)$$

其中, WEU 上传任务数据产生的一部分能耗, 应小于或等于 WEU 所收集的能量, 此时, WEU 剩余能量为

$$E'_{\text{res}} = E_i - \frac{d_i}{r_i} P_i^M \quad (13)$$

为使数据处理的最大化, 令此时 MEC 服务器的计算速率与卸载能力一致, 即

$$R_{M,i} = \partial B \text{lb} \left(1 + \frac{P_i^M g_i t_0}{\sigma^2 T_{M,i}} \right) \quad (14)$$

其中, $P_i^M = E_i / t_{M,i}$ 表示终端用户向 MEC 服务器上传数据的功率, σ^2 表示接收器的背景噪声功率, B 表示信道带宽。

2 系统问题优化

如图 1 所示, MEC 服务器计算任务的结果下传至无线终端用户的时间远小于上传的时间, 所以本文将 MEC 服务器到无线终端用户的下载时间忽略不计, 因此 MEC 的计算时间与本地计算时间之和应小于或等于系统的总体时间, 即

$$t_{M,i} + t_{1,i} \leq T_{\max} \quad (15)$$

根据上述分析, 终端用户的本地计算能耗和 MEC 服务计算产生的总能耗也应小于或等于系统所产生的总能量, 即

$$a_i E_{M,i} + (1 - a_i) E_{1,i} \leq E_i \quad (16)$$

2.1 问题描述

卸载策略的目的是降低计算任务产生的时延和能耗, 进而提升计算速率。本文阐述了 WEU 在

MEC 服务器和本地计算执行任务的情况。根据上述分析, 可以得出执行任务消耗的总能量

$$E_{\text{总}} = a_i E_{M,i} + (1 - a_i) E_{l,i} \quad (17)$$

本文 WEU 产生的计算任务遵循完全的二进制卸载策略, 要么在本地执行, 要么完全卸载至 MEC 服务器执行。为此得到卸载决策矩阵为

$$\mathbf{M}_o = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (18)$$

本文以 WEU 进行动态卸载决策和降低系统总能耗为优化目标, 为平衡传输时延和能量消耗, 将卸载优化问题表达为

$$\min \sum_{\text{WEU}_i=1}^N a_i E_{M,i} + (1 - a_i) E_{l,i} \quad (19)$$

$$\begin{aligned} \text{s.t. } & \text{C1: } a_i t_{M,i} + (1 - a_i) t_{l,i} \leq T_{\max} \\ & \text{C2: } a_i E_{M,i} + (1 - a_i) E_{l,i} \leq E_{\max} \\ & \text{C3: } a_i \in [0, 1], T > 0, E_i > 0 \\ & \text{C4: 式(5), 式(13)} \end{aligned} \quad (20)$$

其中, C1 表示本系统所允许的最大时延, C2 代表 WEU 消耗的能量不能超过 E_{\max} , C3 表示计算任务的卸载决策, C4 表示 WEU 收集的能量应大于其执行任务产生的能耗、大于其上传任务数据所产生的能耗。

2.2 优化问题

面对时变信道状态下的多用户动态卸载, 在达到提高计算速率的同时降低能耗和资源分配合理性。在动态时变的无线信道内, 由上述能耗计算式(4)和式(12), 假设 $f_{l,i}$ 和 $f_{M,i}$ 不变, 则能耗的多少问题与处理任务的时延成正比。因此, 系统处理计算任务的能耗受计算速率的影响。由式(8)和式(14), 假设计算速率仅受信道增益 g_i 的影响, 其他参数均为固定参数。

根据上述分析, 对于 WEU 完成计算任务的最小能耗问题可以转化为最大化系统计算速率问题, 即式(19)的问题可以转化为

P1:

$$Q(a, g, T_{M,i}, T_{l,i}) \triangleq \max \sum_{i=1}^N (a R_{M,i} + (1 - a) R_{l,i}) \quad (21)$$

$$\begin{aligned} \text{s.t. } & \text{C5: } t_{M,i} + t_{l,i} \leq T_{\max} \\ & \text{C6: } t_{M,i} \geq 0, t_{l,i} > 0 \\ & \text{C7: } a_i \in [0, 1] \end{aligned} \quad (22)$$

根据式(22)的分析, 可以得出计算速率最大化 P1 问题是一个非凸的混合整数组合优化问题。

当 $t_{l,i} = 0$ 且 $a_i = 1$ 时, WEU_i 将计算任务卸载至 MEC 服务器进行计算。因此, 当给出 a_i 值时, 问题 P1 则被简化为一个凸优化问题, 可表示为

$$\text{P2: } Q(a, g, T_{M,i}) \triangleq \max \sum_{i=1}^N \partial B \text{lb} \left(1 + \frac{P_i g_i t_0}{\sigma^2 T_{M,i}} \right) \quad (23)$$

$$\text{s.t. } T_{M,i} > 0, t_0 \in (0, T) \quad (24)$$

由式(21)可将问题 P1 转换成解决计算卸载决策问题和时变的信道资源分配的问题, 即 P2 问题。对于 P2 问题, 本文提出一种基于 WPT-MEC 的面向多用户的动态自适应卸载 (RLDO) 方法。

3 卸载方法

本文将多用户的动态自适应卸载问题转化为典型的组合优化问题, 目标是自适应时变的信道状态, 最大化计算速率, 降低计算时延, 减少能量消耗, 更好地满足用户需求。为解决上述等式中定义的优化问题 P2, 本节描述一种基于 WPT-MEC 的面向多用户的动态自适应卸载方法, 即 RLDO 方法。

3.1 深度强化学习方法

深度强化学习的方法旨在系统规定的时间内, 根据系统当前的状态, 通过智能体与环境的不断交互获得奖励, 根据奖励情况对卸载策略不断优化, 最终找到一个最优的策略。有研究者已经证明了传统的动态规划算法可以解决此类问题, 但面对动态衰落时变的信道状态, 较难实现对用户的实时决策的问题, 结合强化学习的方法可以更好地应对此问题。

在系统的每段时间内, 设计一个优化卸载策略的函数 \mathfrak{R} , 信道增益 $g_i > 0$, 该方法就会产生 P2 问题的最优解, 即最优卸载动作 a_i^* , 可以表示为

$$\mathfrak{R}: g_i \rightarrow a_i^*, a_i^* \in (0, 1)^N, g_i > 0 \quad (25)$$

卸载策略的生成主要依靠深度神经网络 (DNN, deep neural network), 借鉴 DRL 的思想, 本文定义的状态空间、动作空间和奖励函数如下。

状态空间: 用 S 表示状态空间, 主要由系统模型 MEC 服务器和用户之间的信道增益、WEU 数量

以及任务数据组成，即 $S = [g_1, g_2, \dots, g_i, \text{WEU}_1, \text{WEU}_2, \dots, \text{WEU}_i, c_i]$ 。

动作空间：用 A 表示动作空间，主要由卸载策略组成，即 $A = [a_1, a_2, \dots, a_i]$ ，WEU 和 MEC 服务器可为处理数据提供计算资源。

奖励函数：根据本文的主要优化目标，在每个步长 t 内，智能体每执行一次 A_t ，都会在该动作的状态 S_t 下收到相应的奖励 R_t ，直到迭代结束。强化学习的目标是在规定时间内获得最大的回报，本文的主要目标是最大化系统的计算速率，将本文目标转化为深度强化学习的优化问题，奖励值与最大化计算速率是正比的关系。为此，将奖励函数表示为 $R = Q(a, g, T_{M,i})$ 。

3.2 动态自适应卸载方法

RLDO 方法架构如图 3 所示，RLDO 方法是由 1 个输入层、4 个隐藏层和 1 个输出层的 6 层架构组成的全连接的 DNN，隐藏层采用 relu 激活函数，输出层采用 sigmoid 激活函数。优化方法采用自适应矩估计 (Adam, adaptive moment estimation) 的方法，将二分类问题与输出层的 sigmoid 函数结合，采用经验回放技术进行训练更新。

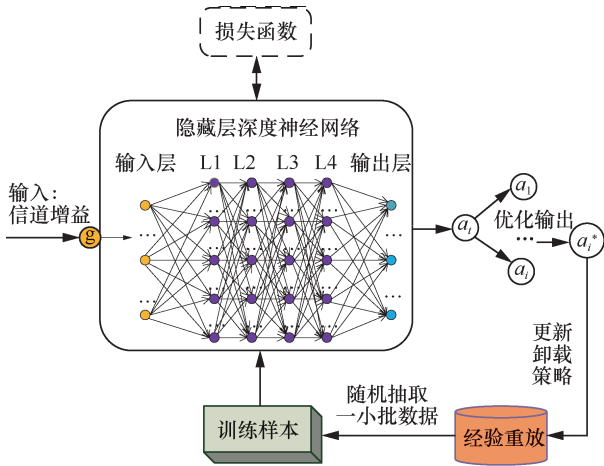


图3 RLDO方法架构

本文方法对产生的二元制卸载动作进行存储，使用 Logistic 回归进行分类，通过特征向量表示为

$$P(y = j | g_i, w, b) = \varphi(z) \quad (26)$$

其中， y 表示输出，代表第 j 类， g_i 表示输入， w 表示权重， b 表示偏差， z 表示回归方程， φ 在本公式中表示模型。回归方程为

$$z = wg_i + b \quad (27)$$

对于二分类，函数 $\varphi(z)$ 可表示为

$$\varphi(z) = \frac{1}{(1 + e^{-z})} = \frac{1}{(1 + e^{-(wg_i + b)})} \quad (28)$$

sigmoid 激活函数产生的 y 值范围为 $[0, 1]$ ，因此在系统时间 T 内可以使用此函数预测分类，卸载动作主要通过 DNN 进行训练、预测和生成。

在系统时间 $t \in T$ 内，信道增益的不断变化，DNN 以信道增益 g_i 、MEC 服务器计算资源和 WEU 作为输入，根据当前的卸载策略函数 \mathfrak{R}_{θ^u} ，DNN 会产生一个随机松弛的卸载动作 $a_i \in [0, 1]$ ，通过不断量化得到 M 个二元制卸载动作，其中 $M \in (1, 2^N)$ ， N 是无线终端用户的数量。当 M 值越大，计算复杂度就会越高，则最后的解也会是最优的。每当网络执行一次卸载动作 a_i ，都会收到一个相应的奖励 $R_t(s_t, a_t)$ ，在转移到下一个状态 s_{t+1} ，并将状态-动作 (g_t, a_t^*) 添加到经验回放缓冲区 ϕ 中。随着用户数量和位置的变化，为减少方法重新训练的代价，降低计算复杂度，本文在 RLDO 方法内采取保序的量化方法，也就是说对于量化随机产生的卸载动作过程中要保持有序，假设 $1 \leq M \leq N + 1$ ，生成的量化动作集合 $\{a_{T,i}\}$ 表示为

$$a_{T,i} = \begin{cases} 1, & y > 0.5 \\ 0, & y \leq 0.5 \end{cases} \quad (29)$$

为输出一个最优的卸载动作，本文采用 Adam 方法将参数 θ^u 更新为 θ^{u+1} ，进而对下一阶段 DNN 生成的卸载动作进行优化，该方法实现相对简单，对存储需求低，比较适用于数据或参数方面较大的问题。该方法根据梯度的一、二阶矩阵估计计算不同参个体的学习速率，可以通过训练适应环境，以便自主更新学习率。

将通过式(29)生成的所有卸载动作进行二元制存储，由于受到存储内存的限制，当内存已满时，新产生的卸载动作数据样本会替换部分原始存储的数据样本，采用经验回放技术，DNN 从最新生成的数据样本中随机抽取一部分数据 I 进行训练，用交叉熵损失函数解决 sigmoid 激活函数收敛速度慢的问题，使损失降到最低，损失函数表示为

$$L(\theta^u) = -\frac{1}{I} \left[(a_i^*)^T \ln f_{\theta^u}(g_i) + (1 - (a_i^*)^T) \ln (1 - f_{\theta^u}(g_i)) \right] \quad (30)$$

其中， $(a_i^*)^T$ 表示 a_i^* 的矩阵， $f_{\theta^u}(g_i)$ 是卸载动作作用

量化参数可表示的形式, 即: $a_i = f_{\theta^{\mu}}(g_i)$, f 为应用适当激活函数的近似连续映射。

RLDO 算法如算法 1 所示, 卸载决策主要用于更新 DNN 的卸载策略, 通过不断训练, 进行多次迭代优化后, 在规定时间内满足所有约束条件的情况下产生一个最优的卸载动作 a_i^* , 最优的卸载动作就是 P2 问题的最佳解。

算法 1 RLDO 算法

输入: 用户数量、MEC 服务器计算资源、信道增益

输出: 在每个时间段 t 内的资源分配情况和最优的卸载动作 a_i^*

```

初始化 DNN 的权重参数  $\theta^{\mu}$ ;
初始化经验重放缓冲区  $\phi$  为空;
设置迭代次数为  $\mathcal{E}$  和训练间隔为  $\rho$ ;
在系统允许的最大时延  $T_{\max}$  内;
for  $t = 1, 2, \dots, T_{\max}$  do
    for  $e = 1, 2, \dots, \mathcal{E}$  do
        重置 WPT-MEC 环境下的实验参数;
        随机生成一个卸载动作  $a_i \in \mathcal{A}_i$ ;
        量化  $a_i$  为  $M$  个二元制卸载动作  $\{a_{T,i}\} = x_A(a_i)$ ;
        计算所有  $\mathcal{R}_i(s_i, a_i)$  生成的动作  $\{a_i\}$  解决 P2 问题;
        满足约束条件式(20)式(22)式(24);
        选择一个最优的卸载策略  $a_i^*$ ;
        通过添加  $(g_i, a_i^*)$  更新经验重放缓冲区  $\phi$ ;
        if  $e \bmod \rho = 0$  then
            选择一个卸载策略, 决定是否进行卸载操作从缓冲区  $\phi$  中随机抽出一批数据  $I$  训练 DNN;
            使用 Adam 优化方法更新参数  $\theta^{\mu'}$ ;
        end if
    end for
end for
    
```

4 仿真设计与结果分析

4.1 环境及参数设置

本实验主要以仿真为主, 仿真环境选择配置和为 Intel (R) Core (TM) i5-7400 3.0 GHz CPU 和 8 GB 内存的个人计算机。采用树莓派 4B 开发板做 MEC 服务器, 在树莓派开发板上安装 TensorFlow

框架, 其内部参数为 8 GB 内存、1.5 GHz 四核 CPU、500 MHz GPU, 操作系统为 Linux 系统。

无线终端用户的数量为 5~30, 在衰落的信道状态下, 根据式(2)计算信道增益, 终端用户产生的任务数据大小为 1 000~8 000 KB, MEC 服务器与用户之间的距离 l_i 为 1.5~4 m。用 Python 开发语言进行仿真实验, DNN 模型的学习率为 0.05, 迭代次数为 1 000~6 000, 训练间隔 $\rho=10$ 。对于无线电能 AP 处的能量发射器, 本文采用 TX91501 Powercaster 发射机的参数, 此发射机专用射频源用于按须射频能量的传输。AP 发射器的输出功率 $P_i = 3$ W, 能量转化率 $\partial = 0.62$, 能效系数 $k = 10^{-26}$, 其余仿真参数见表 1。

表 1 仿真参数

参数	数值
信道带宽/MHz	5
本地服务器计算能力/ (cycle·s ⁻¹)	10 ⁸
MEC 服务器计算能力/ (cycle·s ⁻¹)	3×10 ⁸
载波频率/MHz	915
天线增益	3
路径衰减指数	2.8
信道噪声功率/W	10 ⁻¹⁰

4.2 仿真结果分析

本节将对本文设计的方法进行对比实验分析, 在 PC 端对数据进行处理, 确定任务计算模式, 将处理好的数据下载至 MEC 服务器, 将 RLDO 方法部署在系统的 MEC 服务器上, 在时变的无线信道状态下, 比较无线终端多用户利用本地计算、MEC 和 RLDO 方法进行计算所产生的平均计算速率、平均计算时延、平均能耗。最后与传统的 DQN 方法和 RL 方法以及文献[17]的方法进行对比分析。

仿真分析 1: 比较 RLDO 方法分别在 WEU=5、10、20、30 时, 在相同的时间内, 计算任务的平均计算速率的变化。

不同 WEU 情况下的平均计算速率如图 4 所示, 可以看出, 当 $T=10\ 000$ s 时, WEU_5、WEU_10、WEU_20 和 WEU_30 的计算速率分别约为 95.5%、94.8%、93.9%、93.3%, 在此时间内本系统的平均计算速率可以保持在 93%以上。当 $T=30\ 000$ s 时, WEU_5、WEU_10、WEU_20 和

WEU_30 的平均计算速率分别约为 95.2%、94.4%、93.5%、92.6%，在此时间内系统的平均计算速率保持在 92.5% 以上。当 $T=60\ 000\text{s}$ 时，WEU_5、WEU_10、WEU_20 和 WEU_30 的平均计算速率分别约为 94.6%、93.7%、92.8%、92.1%，即使 WEU 数量达到 30，本方法的平均计算速率仍可以保持在 92% 以上。随着 WEU 数量的不断增加，产生的计算任务也随之增加，在相同的信道时间内，数量为 30 的平均计算速率要明显低于数量为 5 的，但 WEU 数量相同时，在不同的时间内平均计算速率变化较小，说明该方法可以自适应时变的信道状态。




图 4 不同 WEU 情况下的平均计算速率

实验分析 2：针对不同 WEU 数量，与 MEC 服务器有着相同的距离，比较利用本地计算、MEC 和 RLDO 方法执行计算任务产生的平均计算时延的大小变化。

平均计算时延如图 5 所示，随着 WEU 数量的不断递增，利用 3 种方法产生的计算时延也随之增高，但本文 RLDO 方法相较于其他两种方法的变化相对缓慢。当数量较少时，3 种策略平均计算时延差别不是很明显，计算任务可以选择本地计算。当 WEU 数量达到 18 以上，MEC 和本文 RLDO 方法优于本地计算。当 WEU 数量达到 26 以上时，MEC 服务器对时延的敏感度降低许多，利用 MEC 产生的时延明显高于 RLDO 方法，而本文方法为了减少训练代价，降低计算复杂度，采取保序量化的方法。因此本文方法明显优于其他两种策略，当 WEU 数量达到 30 时，本文方法的平均时延计算比本地计算的平均计算时延降低接近一个数量级。




图 5 平均计算时延

实验分析 3：比较 RLDO 方法、MEC 和本地计算在相同的时间内，不同 WEU 数量情况下完成任务的平均计算速率。

平均计算速率如图 6 所示，可以看出，在不同的时间内，本地计算的平均计算速率变化程度要明显高于 MEC 和 RLDO 方法，在短时间内可以适当地选择本地计算。由于 MEC 服务器的计算能力是有限的，进行较长时间任务计算的平均计算速率变化明显。当 $T=60\ 000\text{s}$ 时，三者的平均计算速率的差别更加明显，利用 RLDO 方法进行计算的平均计算速率要远高于其他两种方法。而 RLDO 方法在 3 个不同时间段的平均计算速率差距很小，实验证明本文提出的 RLDO 方法可以更好地自适应时变的信道状态。




图 6 平均计算速率

仿真分析 4：针对不同 WEU 数量，相同的信道时间内，比较 3 种方法完成用户请求任务时的平均能耗情况。

平均能耗如图 7 所示，可以看出计算任务越少，产生的能耗越少，随着 WEU 数量的递增，

产生的任务也在增多, 利用 3 种方法产生的能耗也随之增多, 差距也越来越明显。WEU 数量为 10 时, 本地计算所产生的能耗要略低于 MEC, 终端用户无须进行计算卸载操作(如图 1 中 WEU1 进行本地计算即可)。由于 WEU 计算能力的限制, 随着 WEU 数量的不断增多, 通过本地计算产生的能耗要明显高于 MEC 和 RLDO 方法产生的能耗。虽然 MEC 服务器的计算能力要高于 WEU 的计算能力, 在一定程度上降低了执行任务产生的能耗, 但 WEU 数量达到 20 以上, 需要处理的任务过多时, 显现出计算能力有限的问题, 此时利用 RLDO 方法执行计算任务会减少很多能耗。通过分析, RLDO 方法执行计算任务明显优于其他两种方法, 后期不断适应衰落的信道状态, 能耗的增量逐渐变缓。




图 7 平均能耗

实验分析 5: 在相同的环境下, 对比本文方法与传统的 K-近邻方法和 RL 方法的平均计算速率受 WEU 数量变化的影响。

为更好地体现本文方法的性能, 3 种不同方法的平均计算速率如图 8 所示, 3 种方法执行计算任务的平均计算速率在不同程度上都受 WEU 数量的影响, 本文方法在动态时变的环境下, 可以较好地适应训练, 平均计算速率略高于其他两种方法。KNN 方法和 RL 方法也可以解决任务卸载的优化问题, 本文的实验对比表明, KNN 方法和 RL 方法在一定程度上略逊色于本文 RLDO 方法。当 WEU 数量达到 24 以上, 本文方法的优势越来越明显, 为此, 进一步证明本文方法可以在动态衰落时变的信道状态下, 有效地解决时延敏感型计算任务的卸载问题。




图 8 3 种方法的平均计算速率

实验分析 6: 比较本文方法与文献[17]方法在随着任务数据大小变化时, 系统执行计算任务 WEU 可充电电池内剩余能量的情况。

任务数据大小对剩余能量的影响如图 9 所示, 随着任务数据的不断增加, 各种方法所剩余的能量也会随之减少, 但本文所提的方法优于文献[17]方法。任务数据越大, 本地计算的能量变化速度就越大, 所剩的能量就越少。任务数据值达到 1 500 kB 以上时, 文献[17]方法处理任务的能耗要明显高于本文方法。本文方法在联合优化资源和卸载决策方面可以较好地适应任务数据的变化, 证明本文方法在降低能耗方面有较高的优越性。




图 9 任务数据大小对剩余能量的影响

5 结束语

本文提出一种基于 WPT-MEC 动态自适应卸载

方法。WEU 通过从 AP 获取能量进行通信和计算, WEU 采取完全的二元制卸载策略, 计算任务要么在本地进行计算, 要么完全卸载至 MEC 服务器进行计算。通过比较数量不同的 WEU, 研究时变的无线信道状态对本文方法计算速率的影响, 验证了本文方法可以较好地自适应时变的信道状态, 当 WEU 数量为 30 时, 平均计算速率也可以保持在 92% 以上。通过比较本地计算、MEC 和 RLDO 方法执行计算任务的平均计算速率、平均计算时延和平均能耗的情况。仿真结果表明 RLDO 方法可以有效降低平均能耗和减少平均计算时延, 且平均计算速率要高于其他几种计算方法。为进一步体现本文方法在平均计算速率方面的优越性, 将本文方法与传统的 KNN 和 RL 方法在相同的实验环境下进行比较。为增强本文方法的说服力, 与文献[17]对比分析了用户数量对剩余能量的影响, 再一次验证本文方法的优越性。

本文考虑了单一 MEC 服务器下多用户的计算卸载情况, 可以将此模型扩展至多 MEC 服务器的系统, 再借助云中心强大的计算能力协助解决 MEC 服务器计算能力有限的问题。

参考文献:

- [1] LAGHARIA A, WU K, LAGHARIR A, et al. A review and state of art of internet of things (IoT)[J]. Archives of Computational Methods in Engineering, 2021(29): 1395-1413.
- [2] SUN W, ZHANG H B, WANG R, et al. Reducing offloading latency for digital twin edge networks in 6G[J]. IEEE Transactions on Vehicular Technology, 2020, 69(10): 12240-12251.
- [3] MACH P, BECVAR Z. Mobile edge computing: a survey on architecture and computation offloading[J]. IEEE Communications Surveys & Tutorials, 2017, 19(3): 1628-1656.
- [4] WU J S, GUO S, HUANG H W, et al. Information and communications technologies for sustainable development goals: state-of-the-art, needs and perspectives[J]. IEEE Communications Surveys & Tutorials, 2018, 20(3): 2389-2406.
- [5] ABBAS N, ZHANG Y, TAHERKORDI A, et al. Mobile edge computing: a survey[J]. IEEE Internet of Things Journal, 2018, 5(1): 450-465.
- [6] KAVYASHREE S, CHAVA KUMARI H A. Survey on computation offloading strategies in cellular networks with mobile edge computing[C]//Data Intelligence and Cognitive Informatics. Singapore: Springer, 2022: 567-575.
- [7] 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, 2020, 23(1): 596-630.
- [8] CHEN X H, CAI Y L, LI L Y, et al. Energy-efficient resource allocation for latency-sensitive mobile edge computing[J]. IEEE Transactions on Vehicular Technology, 2020, 69(2): 2246-2262.
- [9] TALEB T, SAMDANIS K, MADA B, et al. On multi-access edge computing: a survey of the emerging 5G network edge cloud architecture and orchestration[J]. IEEE Communications Surveys & Tutorials, 2017, 19(3): 1657-1681.
- [10] JAMALIPOUR A, BI Y. Introduction to wireless powered communication network wireless powered communication networks[EB]. 2019.
- [11] CANNON B L, HOBURG J F, STANCIL D D, et al. Magnetic resonant coupling as a potential means for wireless power transfer to multiple small receivers[J]. IEEE Transactions on Power Electronics, 2009, 24(7): 1819-1825.
- [12] DAHUANG, URZHUMOV Y, SMITH D R, et al. Magnetic superlens-enhanced inductive coupling for wireless power transfer[J]. Journal of Applied Physics, 2012, 111(6): 064902.
- [13] BI S Z, HO C K, ZHANG R. Wireless powered communication: opportunities and challenges[J]. IEEE Communications Magazine, 2015, 53(4): 117-125.
- [14] RANA M M, XIANG W. IoT communications network for wireless power transfer system state estimation and stabilization[J]. IEEE Internet of Things Journal, 2018, 5(5): 4142-4150.
- [15] FENG W M, TANG J, ZHAO N, et al. Hybrid beamforming design and resource allocation for UAV-aided wireless-powered mobile edge computing networks with NOMA[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(11): 3271-3286.
- [16] PSOMAS C, KRIKIDIS I. Wireless powered mobile edge computing: offloading or local computation?[J]. IEEE Communications Letters, 2020, 24(11): 2642-2646.
- [17] LI L, XU G C, LIU P, et al. Jointly optimize the residual energy of multiple mobile devices in the MEC-WPT system[J]. Future Internet, 2020, 12(12): 233.
- [18] LI Y, XIA S C, ZHENG M Y, et al. Lyapunov optimization-based trade-off policy for mobile cloud offloading in heterogeneous wireless networks[J]. IEEE Transactions on Cloud Computing, 2022, 10(1): 491-505.
- [19] GAO L F, MOH M. Joint computation offloading and prioritized scheduling in mobile edge computing[C]//Proceedings of 2018 International Conference on High Performance Computing & Simulation (HPCS). Piscataway: IEEE Press, 2018: 1000-1007.
- [20] ZHANG J, ZHOU L, TANG Q, et al. Stochastic computation offloading and trajectory scheduling for UAV-assisted mobile edge computing[J]. IEEE Internet of Things Journal, 2019, 6(2): 3688-3699.
- [21] YANG T T, FENG H L, GAO S, et al. Two-stage offloading optimization for energy-latency tradeoff with mobile edge computing in maritime Internet of Things[J]. IEEE Internet of Things Journal, 2020, 7(7): 5954-5963.
- [22] SODHRO A H, LUO Z W, SANGAIAH A K, et al. Mobile edge computing based QoS optimization in medical healthcare applications[J]. International Journal of Information Management, 2019, 45: 308-318.
- [23] WANG F, XU J, WANG X, et al. Joint offloading and computing optimization in wireless powered mobile-edge computing systems[J]. IEEE Transactions on Wireless Communications, 2018, 17(3): 1784-1797.
- [24] HUANG L, FENG X, ZHANG C, et al. Deep reinforcement learning-based joint task offloading and bandwidth allocation for multi-user mobile edge computing[J]. Digital Communications and Networks, 2019, 5(1): 10-17.
- [25] HUANG L, BI S Z, ZHANG Y J A. Deep reinforcement learning for

online computation offloading in wireless powered mobile-edge computing networks[J]. IEEE Transactions on Mobile Computing, 2020, 19(11): 2581-2593.

- [26] NGUYEN P X, TRAN D H, ONIRETI O, et al. Backscatter-assisted data offloading in OFDMA-based wireless-powered mobile edge computing for IoT networks[J]. IEEE Internet of Things Journal, 2021, 8(11): 9233-9243.
- [27] ZHANG K, ZHU Y X, LENG S D, et al. Deep learning empowered task offloading for mobile edge computing in urban informatics[J]. IEEE Internet of Things Journal, 2019, 6(5): 7635-7647.
- [28] CHEN J, XING HL, XIAO ZW, et al. A DRL agent for jointly optimizing computation offloading and resource allocation in MEC[J]. IEEE Internet of Things Journal, 2021, 8(24): 17508-17524.
- [29] LI J, GAO H, LYU T, et al. Deep reinforcement learning based computation offloading and resource allocation for MEC[C]//Proceedings of 2018 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2018: 1-6.
- [30] ZHANG R, HO C K. MIMO broadcasting for simultaneous wireless information and power transfer[J]. 2011 IEEE Global Telecommunications Conference-GLOBECOM 2011, 2011: 1-5.
- [31] ZHANG J, HU X P, NING Z L, et al. Energy-latency tradeoff for energy-aware offloading in mobile edge computing networks[J]. IEEE Internet of Things Journal, 2018, 5(4): 2633-2645.

[作者简介]



苏麟（1998-），男，西北师范大学计算机科学与工程学院硕士生，主要研究方向为移动边缘计算、物联网理论与技术等。



党小超（1963-），男，西北师范大学计算机科学与工程学院教授，主要研究方向为智能感知计算、物联网理论与技术等。



郝占军（1979-），男，博士，西北师范大学计算机科学与工程学院教授，主要研究方向为机器学习、移动计算、智能无线网络、被动感知、无线智能感知等。



汝春瑞（1996-），女，西北师范大学计算机科学与工程学院硕士生，主要研究方向为无线定位技术、物联网理论与技术等。



尚旭（1995-），男，西北师范大学计算机科学与工程学院硕士生，主要研究方向为移动边缘计算、物联网理论与技术等。