

面向动态QoS感知的体域网智能边缘算力资源管理算法

穆司琪¹, 文硕¹, 陆杨², 艾渤³

(1. 北京体育大学体育工程学院, 北京 100084; 2. 北京交通大学计算机与信息技术学院, 北京 100044;
3. 北京交通大学电子信息工程学院, 北京 100044)

摘要: 体域网 (BAN, body area network) 是医疗物联网在个人健康监测领域的关键技术, 融合边缘计算实现生理数据实时监测、紧急预警和治疗诊断智能化等服务。然而, 体域网中感知节点计算任务的服务质量 (QoS, quality of service) 随感知数据的紧急程度动态变化, 现有的边缘算力网络资源分配方法难以高效灵活地保障体域网中多源异质任务的动态 QoS。对长时程动态 QoS 感知的计算卸载和边缘算力随机优化问题进行了研究。考虑各体域网多源任务优先级和信道状态变化的马尔可夫性质, 首先将原始的随机优化问题转化为无穷视域的马尔可夫决策过程问题。然后, 构建各体域网的多源任务优先级序列, 提出融合近端策略优化 (PPO, proximal policy optimization) 的深度强化学习任务卸载及算力分配在线决策算法。仿真结果表明, 所提的决策算法优于现有基准算法, 可有效地满足体域网中任务动态优先级需求, 并降低任务完成所需的能量消耗和平均时延。

关键词: 医疗物联网; 边缘计算; 资源管理; 服务质量

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2024.00443

Dynamic QoS-aware intelligent edge computing resource management algorithm for body area networks

MU Siqu¹, WEN Shuo¹, LU Yang², AI Bo³

1. School of Sports Engineering, Beijing Sport University, Beijing 100084, China

2. School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

3. School of Electronics and Information Engineering, Beijing Jiaotong University, Beijing 100044, China

Abstract: Body area network (BAN) is a key technology of the medical Internet of things for personal health monitoring. Integrated with edge computing, it realizes real-time monitoring of physiological data, emergency warning, and intelligent treatment and diagnosis. However, the quality of service (QoS) requirements of the computing tasks in BAN vary with the urgency of the sensing data. The existing resource allocation methods in edge computing network are difficult to efficiently and flexibly support dynamic QoS of multi-source heterogeneous tasks in BAN. A dynamic QoS-aware stochastic optimization problem on computation offloading decisions and edge computing resource allocation was studied. Firstly, considering the Markov nature of multi-source task priorities and channel state changes in BAN, the original stochastic optimization problem was transformed into an infinite horizon Markov decision process problem. Then, a multi-source task priority sequence for each BAN was constructed and an online decision-making method that integrated proximal policy optimization (PPO) was proposed for task offloading and computing resource allocation. The simulation results show that the proposed optimization scheme outperforms existing baseline methods, effectively meeting the dynamic priority requirements of tasks in BAN and reducing the energy consumption as well as the average delay required for

收稿日期: 2024-10-21; 修回日期: 2024-11-19

通信作者: 穆司琪, musiqi@bsu.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62101025)

Foundation Item: The National Natural Science Foundation of China (No. 62101025)

task completion.

Key words: medical Internet of things, edge computing, resource management, QoS

0 引言

近年来,随着物联网等信息技术的大规模研发和商用,智慧医疗等新兴领域取得了长足的进展,智能化的健康风险预警、摔倒检测等计算密集型应用层出不穷^[1-2]。体域网(BAN, body area network)^[3-4]作为医疗物联网的重要组成部分,是实现生命体征实时监测与风险预警的关键技术。BAN通过多个附着在体表或植入体内的惯性传感器和生理传感器节点感知人体运动信息和生理数据,利用短距离无线通信将人体数据传输到移动设备汇聚节点,并进一步通过深度学习等人工智能技术进行生理数据分析。然而,现有的移动设备普遍存在能量、算力等资源受限的问题,无法长时高效地支持大规模体域网用户的智能健康监测及预警等新型应用需求^[5-6]。

在此背景下,边缘计算^[7-8]应运而生。研究人员提出将物联网设备的计算密集型或时延敏感型任务卸载至边缘云以提升任务的处理效率^[9-10]。然而,任务卸载决策会受任务数目和类型、无线网络环境、边缘服务节点拥塞程度和算力资源等诸多因素的影响,因而引发了国内外学者的广泛研究。文献[11-13]针对多用户的并发任务卸载请求,考虑网络和计算环境不发生变化的静态场景,研究了任务卸载决策、无线资源分配及边缘云计算资源分配的耦合关系,将系统中物联网设备的总能耗^[11-12]或任务完成时延^[13]最小化。文献[14]则针对异步到达的任务卸载请求,分析了不同的任务到达时间及任务完成截止时间顺序对于任务本地计算量及卸载量决策的影响。上述文献主要考虑了各用户具有单一的任务类型。

面向BAN中的多源异质任务,文献[15]建立了合作博弈以刻画单个BAN多源传感器的无线资源分配问题,并建立非合作博弈以刻画多个体域网用户进行计算卸载时的资源竞争。文献[16]将BAN用户和边缘服务器间的卸载交互过程建模为斯塔克尔伯格博弈,以实现边缘服务器的能耗最小化和用户的卸载收益最大化的斯塔克尔伯格均衡。考虑无线链路和网络拓扑动态引发的体域网边缘计算系统的

长期性能变化,文献[17-19]研究了动态的机会性计算卸载及资源优化。具体而言,文献[17]建立异质任务多级排队模型以减少控制帧开销,联合优化数据帧融合方式及任务卸载策略,从而最小化任务时延及能量消耗。文献[18]采用最小二乘支持向量机预测模型提取用户行为特征,并根据预测结果制定自适应的通信与计算资源分配方法。文献[19]根据体域网用户的移动行为,进行任务卸载及服务迁移决策设计。虽然现有的体域网边缘计算工作针对体域网多源异质任务和动态网络特性,在任务卸载及通信计算资源优化方面做了诸多开创性工作,但少有研究考虑体域网任务的动态服务质量需求。BAN中,多源传感器感知的用户生理参数动态变化,导致相应的数据分析任务紧急程度和服务需求变化,任务卸载决策、用户间的资源分配等需要实时动态调整,使现有面向已知固定任务类型的卸载决策和算力优化方法不再适用。

本文联合考虑BAN用户类型、感知节点类型和感知数据紧急程度的动态变化,研究动态QoS感知的多源异质任务卸载和算力资源随机优化问题。通过异质任务的动态优先级构建,设计了基于深度强化学习的智能化卸载决策和算力资源分配方法,以适应任务QoS和用户无线链路变化等多种需求。仿真结果表明,所提方法相比现有方法在系统能量消耗和任务完成时间方面具有更优的性能,且灵活的算力分配可提升任务的完成性能。

1 系统模型

系统模型如图1所示,考虑BAN边缘计算系统包含一个边缘服务器和多个BAN用户,BAN用户表示为 $m \in \mathcal{M} = \{1, 2, \dots, M\}$ 。每个BAN用户佩戴多个传感器节点感知生理数据,感知节点集合为 $\mathcal{J} = \{1, 2, \dots, J\}$ 。系统时间分为多个时段,表示为 $t \in \Gamma$ 。各BAN用户在每个时段将产生不同紧急程度的数据分析任务。本文引入关键指标因子 I_m^c 和 I_j^c 来建模BAN用户和感知节点的重要程度。定义BAN用户 $m \in \mathcal{M}$ 的重要性为 I_m^c ,节点 $j \in \mathcal{J}$ 感知数据的重要性为 I_j^c 。 I_m^c 和 I_j^c 值越大,对应的用户及其数据分析任务的优先级越高。例如,心脏病患




图1 系统模型

者的数据分析任务相比健康用户具有更高的优先级，而监控心脏或大脑数据感知节点的 I_j^{pc} 大于监控肌肉感知节点的 I_j^{pc} 。在系统部署阶段，各用户及

其感知数据节点的 I_j^{pc} 与 I_m^{pc} 根据用户类别数目和感知节点类别数目可归一化为(0,1]中的固定值。重要变量及物理含义见表1。

表1 重要变量及物理含义

符号	含义
\mathcal{M}	BAN用户集合
\mathcal{J}	感知节点集合
Γ	时间集合
I_m^{pc}	体域网用户 m 的重要性
I_j^{pc}	感知节点 j 的重要性
$I_j^{dc}(t)$	时段 t 节点 j 的感知数据紧急程度
$I_{m,j}^{com}(t)$	用户 m 任务 j 在时段 t 的服务优先级需求
$G_{m,j}(t)$	用户 m 任务 j 在时段 t 的数据量
$f_m^{loc}(t)$	汇聚节点在时段 t 的本地计算能力
$\alpha_{m,j}(t)$	用户 m 任务 j 在时段 t 的卸载决策
$d_{m,j}^{loc}(t)$	用户 m 任务 j 在时段 t 的本地计算时间
$E_{m,j}^{loc}(t)$	用户 m 在时段 t 处理任务 j 所需能量
W	BAN用户的共用频带
P_m	用户 m 的发送功率
$H_m(t)$	用户 m 在时段 t 的信道增益
$R_m(t)$	用户 m 在时段 t 的卸载传输速率
σ^2	边缘服务器处的噪声功率
$d_{m,j}^{off}(t)$	用户 m 任务 j 在时段 t 的卸载完成时间
$E_{m,j}^{off}(t)$	用户 m 任务 j 在时段 t 的卸载传输能耗
$F(t)$	边缘服务器在时段 t 的总计算能力
$f_m^{mec}(t)$	分配给用户 m 的边缘计算资源
$d_{m,j}^{mec}(t)$	用户 m 任务 j 的计算完成时间
$E_{m,j}^{total}(t)$	用户 m 完成任务 j 所需的总能量
$d_{m,j}^{total}(t)$	用户 m 任务 j 的完成时间

同一感知节点数据分析任务可分为正常任务和紧急异常任务。引入数据关键指标因子 I_j^{dc} 来建模传感器节点的任务重要性，则节点 $j \in \mathcal{J}$ 计算任务的重要性 $I_j^{dc}(t)$ 表示感知数据 $\varphi_j(t)$ 超过预先设定的正常值范围 $[\varphi_j^l, \varphi_j^u]$ 的紧急程度。为计算 $I_j^{dc}(t)$ ，定义感知数据与正常值下界的差值为 $\varphi_j^{sl}(t) = \varphi_j(t) - \varphi_j^l$ ；同理，正常值上界与感知数据的差值为 $\varphi_j^{us}(t) = \varphi_j^u - \varphi_j(t)$ 。则指示函数为

$$u_j(t) = \begin{cases} 1, & \varphi_j^{sl}(t) > 0 \text{ 且 } \varphi_j^{us}(t) > 0 \text{ (正常)} \\ 0, & \varphi_j^{sl}(t) < 0 \text{ 或 } \varphi_j^{us}(t) < 0 \text{ (异常)} \end{cases} \quad (1)$$

式(1)表示在时段 t 的监测数据是否异常。因此， $I_j^{dc}(t)$ 可建模为

$$I_j^{dc}(t) = \begin{cases} 1, & u_j(t) = 1 \\ 1 + \frac{|\varphi_j^{sl}(t)|}{\varphi_j^u - \varphi_j^l}, & u_j(t) = 0 \text{ 且 } \varphi_j^{sl}(t) < 0 \\ 1 + \frac{|\varphi_j^{us}(t)|}{\varphi_j^u - \varphi_j^l}, & u_j(t) = 0 \text{ 且 } \varphi_j^{us}(t) < 0 \end{cases} \quad (2)$$

式(2)融合考虑了BAN用户、感知节点和数据优先级，用户 $m \in \mathcal{M}$ 、任务 $j \in \mathcal{J}$ 在时段 t 的服务优先级需求可定义为 $I_{m,j}^{com}(t) = (I_m^{pc} + I_j^{pc})/2 \times I_j^{dc}(t)$ 。由式(2)可知，正常情况下 $I_j^{dc}(t) = 1$ ， $I_{m,j}^{com}(t)$ 仅与用户和感知节点类型有关；否则， $I_{m,j}^{com}(t)$ 根据 $I_j^{dc}(t)$ 值线性增加。

BAN 用户 m 在时段 t 的任务类型 j 表示为 $[I_{m,j}^{\text{com}}(t), G_{m,j}(t)]$, 其中, $G_{m,j}(t)$ 为任务数据量。假设同一用户的任务以一定次序顺序计算, 处理第 j 种任务 1 bit 数据的计算量为 $C_{m,j}$ 个指令。汇聚节点

$$d_{m,j}^{\text{loc}}(t) = (1 - \alpha_{m,j}(t)) \frac{\sum_{i \in \mathcal{J}} (1 - \alpha_{m,i}(t)) G_{m,i}(t) C_{m,i} + G_{m,j}(t) C_{m,j}}{f_m^{\text{loc}}(t)} \quad (3)$$

$$E_{m,j}^{\text{loc}}(t) = (1 - \alpha_{m,j}(t)) \kappa (f_m^{\text{loc}}(t))^2 G_{m,j}(t) C_{m,j} \quad (4)$$

其中, i 为在任务 j 之前进行本地处理的任务, κ 为能量转换效率系数。

在每个时段, 汇聚节点也可以将部分任务卸载

$$R_m(t) = W \ln \left(1 + \frac{P_m H_m(t)}{\sum_{n \in \mathcal{M} \setminus \{m\}} \mathbb{I} \{ \sum_{i \in \mathcal{J}} \alpha_{n,i}(t) \neq 0 \} P_n H_n(t) + \sigma^2} \right) \quad (5)$$

其中, $\sum_{n \in \mathcal{M} \setminus \{m\}} \mathbb{I} \{ \sum_{i \in \mathcal{J}} \alpha_{n,i}(t) \neq 0 \} P_n H_n(t)$ 为其他 BAN 用户任务卸载造成的干扰, σ^2 为边缘服务器处的噪声功率。通过串行传输, 体域网用户 m 在时段 t 任务 j 的卸载完成时间表示为

$$d_{m,j}^{\text{off}}(t) = \alpha_{m,j}(t) \frac{\sum_{i \in \mathcal{J}} \alpha_{m,i}(t) G_{m,i}(t) + G_{m,j}(t)}{R_m(t)} \quad (6)$$

产生的传输能耗为

$$E_{m,j}^{\text{off}}(t) = \alpha_{m,j}(t) \frac{P_m G_{m,j}(t)}{R_m(t)} \quad (7)$$

同理, i 为在任务 j 之前进行卸载的任务。

此外, 假设边缘服务器在时段 t 的总计算能力为 $F(t)$, 分配给 BAN 用户 m 的计算能力为 $f_m^{\text{mec}}(t)$, 同一用户的任务依次计算, i 为在任务 j 之前进行边缘计算的任务, 则用户 m 任务 j 的计算完成时间为

$$d_{m,j}^{\text{mec}}(t) = \alpha_{m,j}(t) \frac{\sum_{i \in \mathcal{J}} \alpha_{m,i}(t) G_{m,i}(t) C_{m,i} + G_{m,j}(t) C_{m,j}}{f_m^{\text{mec}}(t)} \quad (8)$$

用户 m 任务 j 完成所需的总能耗和完成时间为

$$E_{m,j}^{\text{total}}(t) = E_{m,j}^{\text{loc}}(t) + E_{m,j}^{\text{off}}(t) \quad (9)$$

$$d_{m,j}^{\text{total}}(t) = d_{m,j}^{\text{loc}}(t) + d_{m,j}^{\text{off}}(t) + d_{m,j}^{\text{mec}}(t) \quad (10)$$

因为各用户的信道质量及不同生理传感器的多源数据分析任务紧急性动态时变, 本文最小化长期状态下所有 BAN 用户的能耗和多源任务完成时间加权和。因此, 建立优化问题 P1 如下

$$\begin{aligned} \min_{\alpha_{m,j}(t), f_m^{\text{mec}}(t)} & \sum_{t=0}^{\infty} \sum_{m \in \mathcal{M}} \sum_{j \in \mathcal{J}} I_{m,j}^{\text{com}}(t) (\gamma_1 E_{m,j}^{\text{loc}}(t) + \\ & \gamma_2 d_{m,j}^{\text{total}}(t)) \\ \text{s.t.} & \sum_{m \in \mathcal{M}} f_m^{\text{mec}}(t) \leq F(t) \end{aligned} \quad (11a)$$

(如移动设备) 本地的计算能力表示为 $f_m^{\text{loc}}(t)$ 。定义计算卸载决策变量 $\alpha_{m,j}(t) = 0$ 表示 BAN 用户 m 在时段 t 本地处理任务 j , 否则 $\alpha_{m,j}(t) = 1$, 则其所需的本地计算时间及能量为

到边缘服务器进行计算。假设 BAN 用户共用频带 W , 用户 m 的发送功率为 P_m , 在时刻 t 的信道增益为 $H_m(t)$, 根据香农公式, BAN 用户 m 的卸载传输速率表示为

$$\begin{aligned} \alpha_{m,j}(t) & \in \{0, 1\}, f_m^{\text{mec}}(t) \in [0, F(t)], \\ & \forall j \in \mathcal{J}, \forall m \in \mathcal{M} \end{aligned} \quad (11b)$$

其中, 约束式(11a)表示分配给各体域网用户的计算能力不超过当前时段可用的边缘计算资源, 约束式(11b)为卸载决策及边缘计算资源分配变量。根据上述系统描述, 可以分析出 BAN 用户的多源计算任务完成时间、所消耗的能量等与该用户各任务执行顺序、多个体域网之间的任务卸载决策及分配的计算资源密切相关, 如何最小化能量和时延两种性能指标具有难度。此外, 边缘计算资源的分配与任务卸载决策变量耦合也使单一时段的优化问题难以求解, 而用户的服务质量需求动态变化更为无限视域下的随机优化问题造成了巨大的挑战。

2 动态 QoS 感知的任务卸载及算力分配策略

为解决上述带约束的随机优化问题, 本文首先考虑各 BAN 多源任务优先级和信道状态变化的马尔可夫性质, 将上述长期的随机优化问题转化为无穷视域的马尔可夫决策过程问题。然后, 构建单一用户的多源任务优先级序列, 利用深度强化学习技术, 提出融合近端策略优化 (PPO, proximal policy optimization) 的任务卸载及算力分配在线决策方法, 从而解决本问题中的连续和离散混合变量。

系统状态 $s(t)$ 定义为当前时刻每个 BAN 用户的任务画像、无线链路状态质量和边缘服务器的计算资源, 即

$$s(t) = [I^{\text{com}}(t), \mathbf{G}(t), H_1(t), \dots, H_m(t), F(t) | \forall m \in \mathcal{M}] \quad (12)$$

其中, $I^{\text{com}}(t) = [I_{m,j}^{\text{com}}(t) | \forall m \in \mathcal{M}, \forall j \in \mathcal{J}]$, $G(t) = [G_{m,j}(t) | \forall m \in \mathcal{M}, \forall j \in \mathcal{J}]$, 系统动作表示为

$$a(t) = [\alpha_m(t), f_m^{\text{mec}}(t) | \forall m \in \mathcal{M}] \quad (13)$$

其中, $\alpha_m(t) = [\alpha_{m,j}(t) | \forall j \in \mathcal{J}]$ 。为满足约束式(11a), 将边缘计算资源分配变量进行归一化为 $f_m^{\text{mec}}(t) / \sum_{m \in \mathcal{M}} f_m^{\text{mec}}(t) \cdot F(t)$ 。

之后, 设计奖励函数指导每个时段最优动作的选择。奖励函数 $R(t)$ 定义为当前时段完成所有可卸载任务的能耗、时延及约束惩罚加权值的负值, 表示为

$$R(t) = - \sum_{m \in \mathcal{M}} \sum_{j \in \mathcal{J}} I_{m,j}^{\text{com}}(t) (\gamma_1 E_{m,j}^{\text{total}}(t) + \gamma_2 d_{m,j}^{\text{total}}(t)) \quad (14)$$

根据每一时刻的系统动作 $a(t)$, 定义系统稳态策略 $\pi = \{\pi_1, \dots, \pi_m\}$, 原始的优化问题P1可转化为最小化期望累积奖励, 即

$$\mathcal{R} = \sum_{t=0}^{\infty} \beta^t \mathbb{E}_{\pi} [R(t)] \quad (15)$$

本文将基于PPO进行任务卸载及算力分配的在线决策。针对混合变量的马尔可夫决策过程问题, 传统的策略梯度方法 (如 REINFORCE、Actor-Critic) 计算策略梯度的估计并使用随机梯度上升算法对其进行优化。估计量可以通过对目标进行微分来获得

$$L(\theta) = \hat{\mathbb{E}}_t [\lg \pi_{\theta}(a(t) | s(t)) \hat{A}(t)] \quad (16)$$

其中, $\hat{\mathbb{E}}_t[\cdot]$ 表示采样一批有限样本的经验平均期望, π_{θ} 表示随机策略, $\hat{A}(t)$ 是时间段 t 的优势函数估计值, 即 Q 函数和状态值函数之差。然而, 策略梯度方法存在两个主要问题: 策略更新不稳定; 数据效率低下^[20]。在策略梯度方法中, 策略变化难以预测, 步长更新大导致学习到的策略显著变差, 进而影响训练效果。相反, 步长更新小会导致学习速度变慢。梯度学习最好从最近的经验中学习并加以利用。然而, 当前的策略梯度方法在梯度变化后不再使用之前的样本经验, 数据利用率低且加剧了神经网络的学习过程。PPO 方法是在信任区域策略优化 (TRPO, trust region policy optimization) 算法的基础上发展而来的, 可以有效解决这些问题^[21]。TRPO 通过在每次迭代时对策略更新的大小使用库尔贝克-莱布勒 (KL, Kullback-Leibler) 散度对策略之间的距离进行约束, 以避免在单次更新时策略参数改动太大, 但使用泰勒展开近似、共轭

梯度等方法求解过于复杂。PPO 直接在目标函数中对新旧策略间的距离进行限制。基于重要性采样的思想和神经网络对归一化数据的偏好, PPO 维护一个值网络和一个策略网络。策略网络 $\pi_{\theta}(a(t) | s(t))$ 用于基于先前策略 $\pi_{\theta_{\text{old}}}(a(t) | s(t))$ 细化策略更新, 两者比率被剪裁。基于此, 策略网络的过大更新将受到裁剪阈值 ϵ 的限制, 裁剪后的目标函数描述为

$$L^{\text{CLIP}}(\theta) = \hat{\mathbb{E}}_t \left[\min(r_{\theta}(t) \hat{A}(t), \text{clip}(r_{\theta}(t), 1 - \epsilon, 1 + \epsilon) \hat{A}(t)) \right] \quad (17)$$

其中, $r_{\theta}(t) = \pi_{\theta}(a(t) | s(t)) / \pi_{\theta_{\text{old}}}(a(t) | s(t))$ 为新旧策略概率比值, $\text{clip}(x, h, g) = \max(\min(x, g), h)$ 。该算法优化原始目标函数与 clip 之后的目标函数中的较小版本。

在本问题中, 动态 QoS 感知的 BAN 任务卸载及边缘算力分配算法如算法 1 所示。首先根据初始的系统策略解决单一用户的任务执行次序问题。由问题 P1 的优化目标, 感知节点及其数据紧急程度越高的数据分析任务计算优先级越高。因此, 将用户 m 的 J 个任务基于 $I_j^{\text{nc}} \times I_j^{\text{dc}}(t)$ 进行排序。对于任务 j , 其优先级更高的任务构成的集合表示为 $\chi_j(t)$, 优先级较高的任务在任务 j 之前进行卸载传输和计算。根据其他 BAN 用户的卸载及式(5)计算传输速率。根据式(3)~式(10)可得出完成任务 j 所需的能耗和完成时间, 其中, $i \in \chi_j(t)$ 。之后, 收集小批量轨迹集合并采用随机梯度下降方法进行策略网络和值网络参数更新。最后, 更新状态并迭代执行上述步骤, 算法流程如图 2 所示。在该算法中, 式(8)~式(10)的计算都依赖于算力分配变量, 边缘服务器根据系统状态的变化动态决策任务卸载变量 $\alpha_m(t)$ 及分配给每个 BAN 用户的算力 $f_m^{\text{mec}}(t)$, 并根据式(14)中的瞬时奖励进行任务卸载变量和算力分配变量的学习和调整, 算法最终收敛到稳态策略。

算法 1 动态 QoS 感知的 BAN 任务卸载及边缘算力分配算法

初始化策略网络参数 θ_0 , 值网络参数 ω_0 , 裁剪阈值 ϵ , 初始状态 $s(0)$;

for $t = 1, 2, \dots$ **do**

for $m = 1, 2, \dots, M$ **do**

 基于 $I_j^{\text{nc}} \times I_j^{\text{dc}}(t)$ 将 J 个任务排序, 优先级高

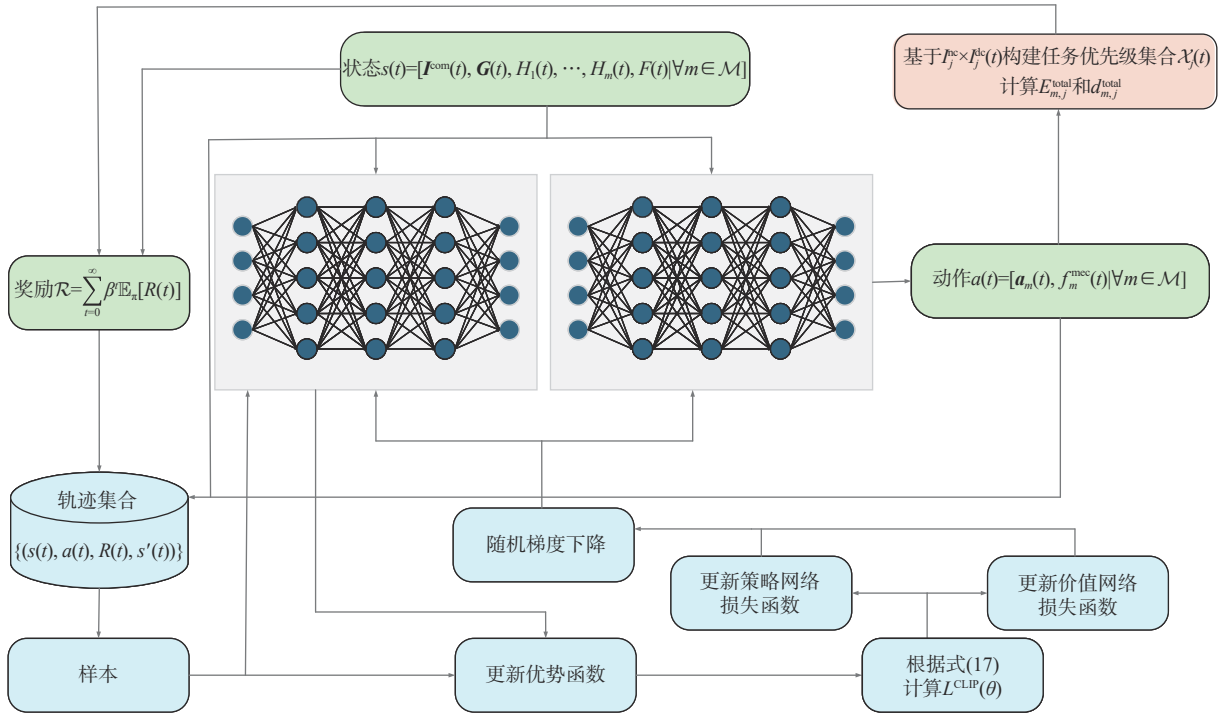


图2 算法流程

于任务 j 的任务集合为 $\chi_j(t)$;

根据策略 $\pi_{\theta_{t-1}}$ 及式(3)~式(10)计算 $E_{m,j}^{total}(t)$ 和 $d_{m,j}^{total}(t)$;

end for

根据策略 $\pi_{\theta_{t-1}}$ 及式(12)~式(14)收集小批量轨迹集合 $\{(s(t), a(t), R(t), s'(t))\}$;

根据 $R(t)$ 和价值网络估计优势函数 $\hat{A}(t)$;

基于策略网络更新策略分布 $\pi_{\theta_t}(a(t)|s(t))$;

根据式(17)计算 $L^{CLIP}(\theta)$;

采用随机梯度下降算法批量更新策略网络参数 $\theta_t = \text{argmax}_{\theta} L^{CLIP}(\theta)$ 和价值网络参数 ω_t ;

更新状态 $s(t) \leftarrow s'(t)$;

end for

3 性能评估

本节将提供仿真结果验证所提方法的有效性。考虑 10 个 BAN 用户均匀分布在 $500 \text{ m} \times 500 \text{ m}$ 的方形区域内，基站与边缘服务器位于区域中心。所有用户共享相同的无线信道，信道带宽为 $W = 1 \text{ GHz}$ 。根据 IEEE 802.15.6 协议^[22]，体域网为不同类型用户提供的服务可分为 4 种，包括非医疗服务、低优先级医疗服务、正常健康服务和高优先级医疗服务。每个 BAN 用户佩戴 8 种不同的生理传感器，

监测背景信息、语音、ECG、体温、动作等 8 种不同优先级的数据类型并产生相应的数据分析任务。因此，经过归一化， $I_m^{pc} \in [0.25, 0.50, 0.75, 1.00]$ ， $I_j^{pc} \in [0.125, 0.250, 0.325, 0.500, 0.625, 0.150, 0.875, 1.000]$ 。感知数据的紧急程度分为正常、紧急和非常紧急 3 种，即 $I_j^{dc}(t) \in [1, 5, 10]$ ，且不同时段的数据紧急程度遵循马尔可夫性，相应的状态转移概率矩阵为 $[0.7, 0.2, 0.1; 0.2, 0.6, 0.2; 0.1, 0.2, 0.7]$ 。任务数据 $G_{m,j}$ 的大小均匀分布在 $50, 100 \times 10^3 \text{ byte}$ 。BAN 用户和基站之间的信道增益遵循两状态的稳态马尔可夫链，增益 1.0×10^{-3} 和 1.0×10^{-5} 分别表示信道状态良好和信道状态较差，并且好到好和差到差的状态转移概率分别为 $p_{gg} = 0.8$ 和 $p_{bb} = 0.7$ ^[23]。各用户汇聚节点的发射功率 P_m 设置为 100 mW ，能量转换系数 κ 为 1.0×10^{-27} ^[24]。高斯噪声的功率谱密度 σ^2/W 为 -174 dBm/Hz 。汇聚节点和边缘服务器的计算速度分别为 $f_m^{loc}(t) = 1 \text{ Gigacycle/s}$ 和 $F(t) = 10 \text{ Gigacycle/s}$ ^[25-26]。期望累积奖励函数式(11)中的 γ_1 和 γ_2 的值均设置为 1，折扣因子 β 设置为 0.9 ^[27]。所提算法相关的超参数包括：策略网络学习率为 1.0×10^{-4} ，价值网络学习率为 5.0×10^{-3} ，隐藏层单元数为 96，批量大小为 64，裁剪阈值 ϵ 为 0.2 ^[28-29]。

为评估所提方法的能耗和延迟性能，本节仿真

了现有文献中的两种方法作为对比。第一种为不考虑QoS需求的随机计算(RCQ, random computing without QoS)^[30], 即所有用户的所有任务不区分计算顺序在本地或边缘服务器进行执行; 第二种为基于深度Q网络(DQN, deep Q network)的边缘计算方法(DEC, DQN-based edge computing)^[31], 即根据每一时段的可卸载任务集合, 边缘计算资源平均分配给所有卸载用户, 并通过DQN进行任务卸载决策。

算法训练值网络损失值变化如图3所示。训练过程包含50轮, 每轮包含100个步长。可以看到随着步长增加, 网络的损失值不断减小并逐渐接近于0, 这表明时间差分目标值与价值网络输出的均方误差逐渐减小, 显示了算法1的收敛性及其对策略的有效学习。




图3 算法训练值网络损失值变化

BAN任务完成所需平均能耗与体域网用户数目关系如图4所示, BAN任务完成平均时延与体域网用户数目关系如图5所示。在开始阶段, 由于BAN用户数目较少, 干扰较小, 且各用户有多种异质任务, 大量任务被卸载至边缘服务器进行计算, 减少了过高的本地计算能耗和计算时延, 各任务完成所需的平均能耗和完成时延较低。随着BAN用户数目增加, BAN之间的干扰逐渐增强, 各用户的传输速率降低, 任务卸载的时间延长, 卸载能耗增加, 且各个体域网用户分配到的算力资源减少, 任务在边缘服务器上的计算时间增加。因此, 3种方法中的平均能耗和平均任务完成时延都进一步增加。

此外, 所提方法的性能比现有的RCQ和DEC方法更好。相比RCQ, 所提方法的性能优势在BAN数目增多时尤为明显, 因为在任务卸载决策和边缘计算资源分配时考虑了不同生理数据的紧急




图4 BAN任务完成所需平均能耗与体域网用户数目关系

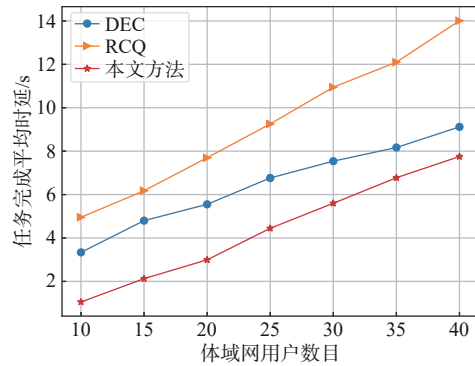


图5 BAN任务完成平均时延与体域网用户数目关系

程度, 所提方法将更加紧迫的任务进行优先卸载或本地计算, 对于用户的平均能耗和任务完成时延减少在任务数目较大时效果显著, 该结果也表明依据任务的动态紧急程度进行边缘卸载和算力分配的必要性。相比DEC, 所提方法在用户数目较少时平均能耗和任务完成时延性能更好, 因为无线干扰较少的情况下更多的用户进行计算卸载, 所提算法能够对多个体域网用户进行更优的边缘算力分配。在BAN用户较多时性能也有一定提升, 如用户数目为40, 平均能耗和任务完成时延的性能分别提升了16.9%和15.0%。

4 结束语

本文研究了医疗物联网中动态QoS感知的计算卸载和边缘算力随机优化问题。通过构建各体域网的多源任务优先级序列, 提出了融合近端策略优化PPO的任务卸载及算力分配智能优化算法。仿真结果表明, 所提优化方案基于任务的动态紧急程度进行边缘卸载决策和算力分配, 有效地降低了用户的平均能耗和任务完成时延, 尤其是面向大规模体域网用户场景。并且, 基于不同体域网用户计算任务量, 所提方法精细化的算力资源分配也实现了更好

的性能增益。在未来研究工作中,将进一步结合医疗物联网实际场景特点,考虑在已知非完美信道的条件下,如何进行算力资源的高效管理。

参考文献:

- [1] PHILIP N Y, RODRIGUES J J P C, WANG H G, et al. Internet of things for in-home health monitoring systems: current advances, challenges and future directions[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(2): 300-310.
- [2] 梁峻阁, 宋怡然, 孙杨帆, 等. 基于可穿戴与可植入技术的人体健康物联网研究进展[J]. *物联网学报*, 2023, 7(2): 26-34.
LIANG J G, SONG Y R, SUN Y F, et al. Research progress of human health IoT based on wearable and implantable techniques[J]. *Chinese Journal on Internet of Things*, 2023, 7(2): 26-34.
- [3] CORNET B, FANG H, NGO H, et al. An overview of wireless body area networks for mobile health applications[J]. *IEEE Network*, 2022, 36(1): 76-82.
- [4] 寇家华, 唐雷, 乔峙, 等. 基于可穿戴计算的体域网技术应用现状与趋势研究[J]. *信息通信技术与政策*, 2020(8): 75-79.
KOU J H, TANG L, QIAO Z, et al. Current situation and trend of body area network based on wearable computing[J]. *Information and Communications Technology and Policy*, 2020(8): 75-79.
- [5] QUY V K, HAU N V, ANH D V, et al. Smart healthcare IoT applications based on fog computing: architecture, applications and challenges[J]. *Complex & Intelligent Systems*, 2022, 8(5): 3805-3815.
- [6] MU S Q, LIAO S W, TAO K, et al. Intelligent fatigue detection based on hierarchical multi-scale ECG representations and HRV measures[J]. *Biomedical Signal Processing and Control*, 2024, 92: 106127.
- [7] HAYYOLALAM V, ALOQAILY M, ÖZKASAP Ö, et al. Edge-assisted solutions for IoT-based connected healthcare systems: a literature review[J]. *IEEE Internet of Things Journal*, 2022, 9(12): 9419-9443.
- [8] DUAN S J, WANG D, REN J, et al. Distributed artificial intelligence empowered by end-edge-cloud computing: a survey[J]. *IEEE Communications Surveys & Tutorials*, 2023, 25(1): 591-624.
- [9] 张依琳, 梁玉珠, 尹沐君, 等. 移动边缘计算中计算卸载方案研究综述[J]. *计算机学报*, 2021, 44(12): 2406-2430.
ZHANG Y L, LIANG Y Z, YIN M J, et al. Survey on the methods of computation offloading in mobile edge computing[J]. *Chinese Journal of Computers*, 2021, 44(12): 2406-2430.
- [10] DUAN S J, LYU F, WU H Q, et al. MOTO: mobility-aware online task offloading with adaptive load balancing in small-cell MEC[J]. *IEEE Transactions on Mobile Computing*, 2024, 23(1): 645-659.
- [11] XIAO Y L, XIAO L, WAN K P, et al. Reinforcement learning based energy-efficient collaborative inference for mobile edge computing[J]. *IEEE Transactions on Communications*, 2023, 71(2): 864-876.
- [12] ZHAO M X, YU J J, LI W T, et al. Energy-aware task offloading and resource allocation for time-sensitive services in mobile edge computing systems[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(10): 10925-10940.
- [13] ZHANG L J, SONG Q Y, WU M R, et al. Joint terminal pairing and multi-dimensional resource allocation for cooperative computation in a WP-MEC system[J]. *IEEE Transactions on Green Communications and Networking*, 2023, 7(3): 1447-1456.
- [14] EOM S, LEE H, PARK J, et al. Asynchronous protocol designs for energy efficient mobile edge computing systems[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(1): 1013-1018.
- [15] NING Z L, DONG P R, WANG X J, et al. Mobile edge computing enabled 5G health monitoring for Internet of medical things: a decentralized game theoretic approach[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(2): 463-478.
- [16] ZHANG R R, LI H, QIAO Y Y, et al. Deep learning-based task offloading and time allocation for edge computing WBANs[C]// *Proceedings of the GLOBECOM 2022—2022 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2022: 2206-2211.
- [17] YUAN X M, ZHANG Z D, FENG C J, et al. A DQN-based frame aggregation and task offloading approach for edge-enabled IoMT[J]. *IEEE Transactions on Network Science and Engineering*, 2023, 10(3): 1339-1351.
- [18] ZHANG L, YUAN X M, LUO J Q, et al. An adaptive resource allocation approach based on user demand forecasting for E-healthcare systems[C]// *Proceedings of the 2022 IEEE International Conference on Communications Workshops (ICC Workshops)*. Piscataway: IEEE Press, 2022: 349-354.
- [19] YUAN X M, ZHU Y S, ZHAO Z Y, et al. An A3C-based joint optimization offloading and migration algorithm for SD-WBANs[C]// *Proceedings of the 2020 IEEE Globecom Workshops (GC Wkshps)*. Piscataway: IEEE Press, 2020: 1-6.
- [20] SUTTON R S. Reinforcement learning: an introduction[J]. *IEEE Transactions on Neural Networks*, 2005, 16: 285-286.
- [21] SCHULMAN J, WOLSKI F, DHARIWAL P, et al. Proximal policy optimization algorithms[J]. *arXiv preprint*, 2017, arXiv: 1707.06347.
- [22] KWAK K S, ULLAH S, ULLAH N. An overview of IEEE 802.15.6 standard[C]// *Proceedings of the 2010 3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies (ISABEL 2010)*. Piscataway: IEEE Press, 2010: 1-6.
- [23] CHANDRAKASAN A, SHENG S, BRODERSEN R. Low-power CMOS digital design[J]. *IEEE Journal of Solid-State Circuits*, 1992, 27: 473-484.
- [24] WANG H S, MOAYERI N. Finite-state Markov channel—a useful model for radio communication channels[J]. *IEEE Transactions on Vehicular Technology*, 1995, 44(1): 163-171.
- [25] CHEN X F, ZHANG H G, WU C, et al. Optimized computation offloading performance in virtual edge computing systems via deep reinforcement learning[J]. *IEEE Internet of Things Journal*, 2019, 6(3): 4005-4018.
- [26] LI H, XIONG K, LU Y, et al. Distributed design of wireless powered fog computing networks with binary computation offloading[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(4): 2084-2099.
- [27] MU S Q, ZHONG Z D, ZHAO D M. Energy-efficient and delay-fair mobile computation offloading[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(12): 15746-15759.

- [28] ZHANG R C, XIONG K, LU Y, et al. Energy efficiency maximization in RIS-assisted SWIPT networks with RSMA: a PPO-based approach[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(5): 1413-1430.
- [29] ZHANG Y C, LU Y, ZHANG R C, et al. Deep reinforcement learning for secrecy energy efficiency maximization in RIS-assisted networks[J]. IEEE Transactions on Vehicular Technology, 2023, 72(9): 12413-12418.
- [30] JIANG F, QIN J W, LIU L, et al. Associative tasks computing offloading scheme in Internet of medical things with deep reinforcement learning[J]. China Communications, 2024, 21(4): 38-52.
- [31] YUAN X M, TIAN H S, ZHANG Z D, et al. A MEC offloading strategy based on improved DQN and simulated annealing for Internet of behavior[J]. ACM Transactions on Sensor Networks, 2023, 19(2): 1-20.

[作者简介]



穆司琪(1993-), 女, 博士, 北京体育大学体育工程学院助理教授, 主要研究方向为医疗物联网、边缘计算、体域网及其在健康医疗领域的应用等。



文硕(2000-), 男, 北京体育大学体育工程学院硕士生, 主要研究方向为体域网及其在健康医疗领域的应用等。



陆杨(1992-), 男, 博士, 北京交通大学计算机与信息技术学院教授, 主要研究方向为移动通信。



艾渤(1974-), 男, 博士, 北京交通大学电子信息工程学院教授, 主要研究方向为移动通信。