

DOI:10.20079/j.issn.1001-893x.220916002

基于任务生灭过程模型的边缘计算 批处理调度算法分析与设计*

罗雨, 顾忆宵, 夏斌

(上海交通大学 电子信息与电气工程学院, 上海 200240)

摘要:移动边缘计算技术为低时延要求、资源敏感的计算任务需求提供解决方案,通过研究任务请求特征以提高调度算法效率是边缘计算的重要研究方向。不同于现有研究将任务请求特征建模为单一随机变量的做法,提出基于任务请求生灭过程模型的边缘计算架构,将求解最优调度决策的过程建模为无限期平均成本马尔可夫决策过程。在使用贝尔曼方程分析问题的过程中,利用任务的生灭特性对未来的请求到达做出估计以判断当前决策对未来系统时延能耗成本的影响,进而辅助确定当前状态的最优决策,并结合任务相关性感知提出批处理任务调度控制算法。所提算法根据生灭状态信息对策略迭代的状态空间和决策空间进行剪枝以降低策略改进的复杂度,突破了策略迭代算法的复杂度瓶颈。仿真结果表明,所提算法相较于传统的策略迭代算法具有明显的低复杂度优势,且能在不同系统条件下保持低时延、能耗成本。

关键词:边缘计算;生灭过程;批处理调度决策;马尔可夫决策过程

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN915 文献标志码:A 文章编号:1001-893X(2024)02-0169-08

Batched Scheduling for MEC Systems with Task Birth-Death Dynamics: Analysis and Optimization

LUO Yu, GU Yixiao, XIA Bin

(School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: Mobile edge computing technology provides solutions for latency and resource sensitive computing tasks and it is important to improve the efficiency of scheduling algorithms through task features. Unlike existing researches that model task request characteristics as a single random variable, this paper proposes an edge computing architecture based on the birth-death feature of tasks, modeling an infinite horizon average cost Markov decision process (MDP). In the process of analyzing the problem using the Bellman equation, the birth-death characteristics of the task are used to estimate the future request arrivals to determine the impact of the current decision on the future system cost, and then assist in determining the optimal decision for the current state, and propose a batched scheduling control algorithm. The proposed algorithm prunes the state space and decision space of policy iteration based on the birth-death information to reduce the complexity of policy improvement, which breaks the complexity bottleneck of policy iteration algorithm. Through numerical results, it is inferred that the proposed algorithm has obvious low-complexity advantages over the traditional policy iteration algorithm and can maintain low latency and energy cost under different system conditions.

Key words: edge computing; birth-death process; batched scheduling; Markov decision process

* 收稿日期:2022-09-16;修回日期:2022-11-02

基金项目:国家自然科学基金资助项目(61771307);教育部-中国移动科研基金(MCM20180102);上海市市级科技重大专项(2021SHZDZX0102)

通信作者:罗雨 Email:rei_rui@sjtu.edu.cn

0 引言

移动边缘计算技术 (Mobile Edge Computing, MEC) 在网络边缘接收处理用户卸载的计算任务, 缓解核心网络拥堵的同时提高用户的体验特质 (Quality of Experience, QoE)、降低计算任务的处理成本, 在移动互联网时代得到快速发展。研究者们通过对增强现实^[1] 和在线游戏^[2] 等边缘计算场景下的计算任务展开内容相关性和请求动态特征的研究以降低资源开销、提高服务器工作效率。

文献[3-4]对任务相关性展开了研究、通过构建任务相关性感知的任务卸载机制以提高调度算法的性能表现, 后者进一步引入了计算任务的迁移特征并建立马尔可夫决策过程 (Markov Decision Process, MDP)。利用任务相关性建立同类任务并行计算的处理机制可以减少计算开销。文献[5-6]进一步从任务请求动态变化的角度出发进行讨论, 前者将用户请求的到达情况建模为随机变量并基于排队模型进行优化研究, 后者对车联网边缘计算场景下的计算任务随车辆运动的特征变化做出了讨论。任务动态变化特征可用于预测任务的未来变化趋势, 辅助设计动态规划算法。

但上述研究忽略了计算任务的生灭特性, 该特性在无线网络环境下广泛存在, 如视频编码任务^[7]、新移动应用计算任务^[8] 等。这一缺失降低了任务请求动态特征描述的准确性, 同时使得动态规划算法难以突破当前的复杂度瓶颈得到进一步优化。基于此, 本文综合考虑任务相关性感知和生灭动态特征构建 MEC 架构, 利用相关性特征设计任务处理机制降低时延能耗成本, 并在现有任务请求动态特征研究的基础上进一步将任务请求的到达情况建模为生灭过程。在使用贝尔曼方程求解无限期平均成本马尔可夫决策问题的过程中, 通过提取任务请求的生灭特征对未来变化趋势作出判断, 进而估计调度策略的时延能耗成本以辅助求得最优策略。这一优化定理对策略迭代操作进行状态空间和决策空间的剪枝以提高系统性能, 基于此提出批处理调度算法。所提算法综合考虑任务的相关性和动态特征以取得性能优势, 并通过基于生灭特征的剪枝方法突破了策略迭代的复杂度瓶颈。

1 系统模型

考虑一个离散时间多用户的 MEC 系统, 网络中存在一个与云端服务器相连接的 MEC 服务器以及

K 个与 MEC 服务器相连接的独立用户, 记作 $\mathcal{K} = \{1, 2, 3, \dots, K\}$, 如图 1 所示。用户将请求卸载至接入点 (Access Point), 对应的边缘服务器将用户请求存储到队列中, 运算完成后将结果传输给用户, 超出边缘服务器承载能力的请求会卸载到云端服务器进行处理。

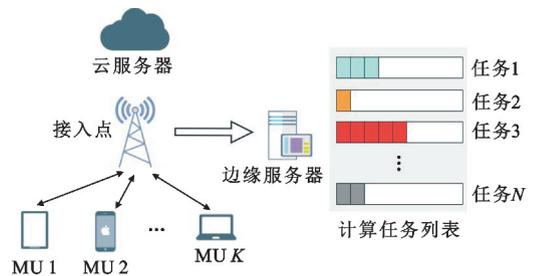


图 1 基于任务相关性感知的 MEC 系统
Fig. 1 Task correlation-based MEC system

1.1 任务模型

将服务时间以秒为单位划分为多个长度为 τ 的时隙, 有索引 $t \in \mathbb{N}_+$, 用户在每个时隙随机向服务器卸载请求, 考虑该边缘计算场景中有 N 种计算任务的请求, 记作 $\mathcal{N} = \{1, 2, 3, \dots, N\}$ 。将用户 $k \in \mathcal{K}$ 在 t 时隙卸载的属于任务类型 n 的请求的数量记作 $r_{n,k}(t)$, 所有用户卸载的属于任务类型 n 的请求总数记作 $a_n(t) \triangleq \sum_{k \in \mathcal{K}} r_{n,k}(t)$, 有 $\mathbf{r}(t) \triangleq \{r_{n,k}(t) : n \in \mathcal{N}, k \in \mathcal{K}\}$, $\mathbf{a}(t) \triangleq \{a_n(t) : n \in \mathcal{N}\}$ 。

计算任务的生灭变化建模如下: 在任务类型 n 处于生状态时, 这一类别的请求会在用户处产生并被卸载到 MEC 服务器; 当任务类型 n 处于灭状态时, 这一类别的请求不会被卸载到服务器。用 $b(t) \triangleq \{b_n(t) : n \in \mathcal{N}\}$ 表示任务的生灭状态。当 $b_n(t) = 1$, 任务类型 n 在 t 时隙处于生状态。当 $b_n(t) = 0$, 任务类型 n 在 t 时隙处于灭状态。以 VR 场景为例, 场景内事件的发生会带来一系列计算任务, 这些计算任务随交互事件的出现消失而出现消失, 交互事件出现时对应任务类型处于生状态, 出现前或消失后处于灭状态。

任务的生灭变化情况用状态转移变量 $s_n^1(t)$, $s_n^2(t) \in \{0, 1\}$ 来表示, 其中 $s^1(t) \triangleq \{s_n^1(t) : n \in \mathcal{N}\}$, $s^2(t) \triangleq \{s_n^2(t) : n \in \mathcal{N}\}$ 。对于灭状态的任务类别 n , 其向生状态的变化由 $s_n^1(t)$ 指明。如果 $b_n(t) = 0$, 则有 $b_n(t+1) = s_n^1(t)$ 。对于生状态的任务类别 n , 其向灭状态的变化由 $s_n^2(t)$ 指明。如果 $b_n(t) = 1$, 则有 $b_n(t+1) = 1 - s_n^2(t)$ 。整个系统处于生状态的任务类

别数量的出生率为 $\sum_{n \in \mathcal{N}} s_n^1(t)$, 死亡率为 $\sum_{n \in \mathcal{N}} s_n^2(t)$, 任务类别数量变化为生灭过程^[9]。任务类别 n 的生灭变化动态过程可以表示如下:

$$b_n(t+1) = 1(b_n(t) = 1)(1 - s_n^2(t) + 1(b_n(t) = 0)s_n^1(t)) \quad (1)$$

式中: $1(\Omega)$ 为指示函数, 满足条件 Ω 时值为 1, 否则为 0。时隙 t 新到的来自用户 k 的属于任务类别 n 的请求数量可以表示为 $r_{n,k}(t) \cdot b_n(t)$ 。

1.2 调度模型

t 时隙 MEC 服务器队列中累积的同属于类别 n 的任务请求的数量记作 $q_n(t)$ 。在每个时隙开始时, 服务器会选择一部分类别的任务请求来进行处理运算。用指示变量 $u_n(t) \in \{0, 1\}$ 来标记类别 n 的被选情况: 当 $u_n(t) = 1$ 时, 类别 n 的请求将会在 t 时隙进行处理, 并在下一时隙将结果传输给用户, 否则 $u_n(t) = 0$ 。相应地, 把 t 时隙的调度决策记作 $\mathbf{u}(t) \triangleq \{u_n(t) | n \in \mathcal{N}\} \in U$, 决策空间大小为 $|U|$ 。将 t 时隙决定进行处理的任务请求类别集合记作 $\mathcal{N}(t) = \{n | u_n(t) = 1, n \in \mathcal{N}\}$ 或 \mathcal{N}_t , 类别数目记作 $m(t) = \sum_{n \in \mathcal{N}} u_n(t)$ 。

如果决定对类别 n 的任务请求进行处理, 则会将 MEC 服务器队列中累积的所有该类别的请求一并处理, 同时清空请求队列 $q_n(t)$ 。因此, 由用户 k 卸载的属于类别 n 的请求队列动态变化情况表示如下:

$$q_{n,k}(t+1) = \min\{1(u_n(t) \neq 1)q_{n,k}(t) + r_{n,k}(t) \cdot b_n(t), q_{\max}\} \quad (2)$$

式中: q_{\max} 是单个用户卸载的单类任务请求在服务器处的最大存储数量。在此基础上将类别 n 的任务请求积累数量记作 $q_n(t) = \sum_{n \in \mathcal{N}} q_{n,k}(t)$, 对于时延容忍度为 T_n 的任务类别 n , 对应的 t 时隙的时延成本可以记作 $D_n(t) = q_n(t) \cdot T_n$ 。同时整个系统在 t 时隙的总时延成本为

$$D(t) = \sum_{n \in \mathcal{N}} q_n(t) \cdot T_n \quad (3)$$

超出服务器存储能力 q_{\max} 的请求需要迁移到云端服务器进行处理^[10], 将其产生的额外时延成本记作迁移成本:

$$L_{n,k}(t) = \max\{1(u_n(t) \neq n)q_{n,k}(t) + r_{n,k}(t) \cdot b_n(t) - q_{\max}, 0\} \quad (4)$$

$$L(t) = \sum_{n \in \mathcal{N}, k \in \mathcal{K}} L_{n,k}(t) \quad (5)$$

1.3 计算模型

类别 n 的任务请求相关参数可以表示为 $\langle I_n,$

$O_n, C_n, T_n \rangle, I_n$ (单位: b), O_n (单位: b), C_n (单位: 每比特所需 CPU 周期) 分别代表该类任务请求的输入数据量、输出数据量、每比特数据计算所需 CPU 周期数。

MEC 服务器在物理机上建立多个虚拟机以实现对多类任务请求的并行处理^[11]。VR 等任务相关性感知的场景下, 可以将相同任务类型的多个请求一并计算^[3, 12]。为了确保在一个时隙内完成计算,

分配给单个虚拟机的最低 CPU 频率为 $f_n(t) = \frac{I_n C_n}{\tau}$,

相应的计算能耗为

$$E_n^1(t) = \kappa I_n C_n f_n^2(t) \quad (6)$$

进而得到整个系统在 t 时隙的总计算能耗为

$$E^1(t) = \sum_{n \in \mathcal{N}} \kappa I_n C_n f_n^2(t) u_n(t) \quad (7)$$

式中: κ 为有效开关电容^[13]。考虑到 MEC 服务器处的计算资源限制, 同一时隙内最多可并行使用的虚拟机数量上限为 m_{\max} ^[14], 因此一次调度决策中决定进行处理的任务种类数量存在上限 $m(t) \leq m_{\max}$ 。

1.4 通信模型

着眼于通信资源受限的计算结果下行传输部分^[15]。下行无线信道建模为块衰落的有限状态马尔可夫信道^[16], 将 t 时隙内用户 k 与接入点之间的信道增益记作 $h_k(t)$, 对应的可达速率 (单位: b/s) 为

$$r_{n,k}(t) = B \log \left(1 + \frac{P_{n,k}(t) h_k(t)^2}{N_0} \right) \quad (8)$$

式中: $P_{n,k}(t), B, N_0$ 分别为传输功率、可用带宽以及复白高斯信道噪声的方差。为了在长度为 τ 的一个时隙内完成对数据量为 O_n 的计算结果的传输, 传输速率必须达到 O_n/τ 。传输功率会受到用户中信道状态最差者的限制, 即 $h_n(t) \triangleq \min_{k \in \mathcal{K}_n(t)} h_k(t)$, $\forall n \in \mathcal{N}$, 其中 $\mathcal{K}_n(t) \triangleq \{k | q_{n,k}(t) > 0, k \in \mathcal{K}\}$ 。考虑以上因素, 系统在 t 时隙进行任务类别 n 的计算结果的传输能耗表示如下:

$$E_n^2(t) = \frac{\tau}{h_n(t)^2} f \left(\frac{O_n}{\tau} \right) \quad (9)$$

式中: $f(x) = N_0 (2^{\frac{x}{B}} - 1)$, $B \triangleq \frac{B_{\text{total}}}{m_{\max}}$ 代表分配给该任务类别的带宽, B_{total} 为系统可用的总带宽。系统在该时隙的总计算能耗为

$$E^2(t) = \sum_{n \in \mathcal{N}} \frac{\tau}{h_n(t)^2} f \left(\frac{O_n}{\tau} \right) u_n(t) \quad (10)$$

2 问题建模与最优性分析

本节将基于上述 MEC 模型建立起优化问题并

说明所采用的研究方法。首先基于贝尔曼方程对马尔可夫决策过程的值函数进行单调性分析,之后根据任务请求队列和生灭状态特征以及问题结构提出数条优化命题。

2.1 问题建模

t 时隙开始时,MEC 服务器需要根据系统状态 $S(t) \triangleq \{q(t), b(t)\} \in \mathcal{S}$ 来确定调度决策 $u(t)$,将这一过程中使用的控制策略 μ 定义为由系统状态到调度决策的映射关系 $\mu: \{q, b\} \rightarrow u$,函数表示为 $\mu(q, b) = u$ 。在后续的讨论中,前述时延、能耗成本可以表示为系统状态 $\{q, b\}$ 和调度决策 u 的函数:时延成本表示为 $D(q)$,计算能耗成本表示为 $E^1(u)$,通信能耗成本表示为 $E^2(q, u)$,迁移成本表示为 $L(q, u)$ 。

引入加权和的方法对各项成本进行统筹优化,该 MEC 系统的一步加权成本可以表示如下:

$$g(q, u) \triangleq D(q) + \omega_1 E^1(u) + \omega_2 E^2(q, u) + \omega_3 L(q, u) \quad (11)$$

式中: $\omega_1, \omega_2, \omega_3$ 分别为计算能耗成本、通信能耗成本、迁移成本的权重参数。给定稳定的单链控制策略 μ ,系统的长期平均成本可以表示如下:

$$\bar{g}(\mu) \triangleq \limsup_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T E[g(q(t), \mu(q(t), b(t)))] \quad (12)$$

为了最小化式(12)中的平均系统成本 \bar{g} ,需要找到最优的控制策略,对应给出优化问题。

问题 1 长期系统成本最小化问题:

$$\bar{g}^* = \min_{\mu} \limsup_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T E[g(q(t), \mu(q(t), b(t)))] \quad (13)$$

式中: \bar{g}^* 为最优策略 μ^* 所对应的最小平均成本。

2.2 问题讨论

值迭代(Value Iteration, VI)和策略迭代(Policy Iteration, PI)都是解决 MDP 问题的常用方法。考虑到本研究中优化问题核心在于找到最优策略,同时策略迭代在许多情况下的性能表现优于值迭代^[17],因此将策略迭代的方法作为研究的中心,并以此为基础进行优化理论的设计。

问题 1 是一个单链无限期平均成本马尔可夫决策问题,状态空间和决策空间有限,存在最优的确定性平稳策略,可以通过如下贝尔曼方程求得:

$$\bar{g}^* + V(q, b) = \min_{u \in U} \{g(q, b) + \sum_{S' \in \mathcal{S}} \Pr[S' | S, u] (V(q', b'))\} \quad (14)$$

式中: \bar{g}^* 为最优控制策略 μ^* 所对应的最小平均成本; $V(\cdot)$ 为值函数。后续部分讨论中使用值函数 $V(q', b')$ 的期望 $E(V(q', b'))$ 来代替 $\sum_{S' \in \mathcal{S}} \Pr[S' | S, u] (V(q', b'))$,即

$$\bar{g}^* + V(q, b) = \min_{u \in U} \{g(q, u) + E(V(q', b'))\} \quad (15)$$

引入状态-决策成本函数 $J(q, b, u) \triangleq g(q, u) + E(V(q', b'))$,代入式(15)可得

$$\mu^*(q, b) = \operatorname{argmin}_{u \in U} J(q, b, u), \forall S = (q, b) \in \mathcal{S} \quad (16)$$

2.3 最优性分析

以模型中请求队列和生灭状态动态变化的特征为基础,结合值迭代的方法,分析得到值函数 $V(S)$ 的如下性质:

引理 1 值函数的单调性:对于任意一组系统状态 $S^1 = (q^1, b^1), S^2 = (q^2, b^2) \in \mathcal{S}$ 满足 $S^1 \leq S^2$,有 $V(S^1) \leq V(S^2)$ 。

因篇幅所限,引理 1 的证明请用微信扫描本文 OSID 码,在“开放科学数据与内容”中查看。

以引理 1 为基础,结合问题的结构特征,可以得到关于 $J(q, b, u)$ 的如下性质:

命题 1 状态-决策成本函数关于请求队列状态的单调性:对于任意调度决策 $u, v \in U$,有

$$J((q + e_{n,k}, b), u) - J((q + e_{n,k}, b), v) \leq J((q, b), u) - J((q, b), v) \quad (17)$$

式中: $e_{u,k}$ 为一个 $N \times K$ 矢量($n \in N_u, k \in \mathcal{K}$),只有在 (n, k) 这一处的值为 1,其他都为 0。

命题的证明与文献[18]引理 3 类似。

命题 1 说明,对于系统状态 $\{q, b\}$ 和调度决策 u, v ,如果状态-决策成本函数满足 $J((q, b), u) \leq J((q, b), v)$,则对于衍生状态 $(q + e_{n,k}, b)$,决策之间的优劣关系仍然成立,有 $J((q + e_{n,k}, b), u) - J((q + e_{n,k}, b), v) \leq 0$ 。派生状态与原状态的生灭特征相同,队列状态的差别满足命题 1。由命题 1 出发,可以得到如下定理:

定理 1 最优策略的最优性继承:使用策略迭代算法寻找最优策略 μ^* 的过程中,如果式(18a)和(18b)条件成立, $u = \mu^*(q^2, b)$,则有 $\mu^*(q^1, b) = \mu^*(q^2, b)$ 。

$$q_{n,k}^1 \geq q_{n,k}^2, \forall n \in N_u \quad (18a)$$

$$q_{n,k}^1 = q_{n,k}^2, \forall n \notin N_u \quad (18b)$$

定理 1 表明,在策略改进步骤中计算状态 $\{q^1, b\}$ 所对应的最优调度决策时,如果已经求得状态

$\{q^2, b\}$ 的最优调度决策, 同时这两个状态满足命题 1 所述关系, 则状态 $\{q^2, b\}$ 的最优决策同时也是状态 $\{q^1, b\}$ 的最优决策。定理 1 的方法对策略改进过程中所需要遍历的状态空间进行剪枝以降低计算复杂度。

基于引理 1 和 $J(q, b, u)$ 的性质, 另有如下命题:

命题 2 决策关于生灭状态的最优性: 对于系统状态 $\{q, b\}$ 和调度决策 $u = \mu(q, b) \in U$, 其中满足 $\exists n \in \mathcal{N}, b_n = 0, q_n > 0, u_n = 0, m = \sum_{n \in \mathcal{N}} u_n < m_{\max}$, 如果式 (19) 成立, 则有 $J((q, b), u^*) < J((q, b), u)$ 。

$$D_n \cdot q_n - (1 - \sigma)(\omega_1 E_n^1 + \omega_2 E_n^2) > 0 \quad (19)$$

$$\sigma = \sum_{(q^0, b^0) \in S^0} \Pr((q^0, b^0) | (q, b), \mu(q, b)) \quad (20a)$$

$$S^0 = \{(q^0, b^0) | \Pr((q^0, b^0) | (q, b), \mu(q, b)) > 0, u_n^0 > 0\} \quad (20b)$$

$$u^0 = \mu(q^0, b^0) \quad (20c)$$

因篇幅所限, 命题的证明请用微信扫一扫本文 OSID 码, 在“开放科学数据与内容”中查看。

命题 2 表明, 给定控制策略 μ , 如果有一组系统状态 $\{q, b\}$ 与对应的调度决策 $u = \mu(q, b)$ 满足命题 2 所述条件, 则控制策略 μ 不是最优策略, 且最优策略 μ^* 严格优于 μ 。由命题 2 出发, 可以得到如下定理:

定理 2 最优策略的决策剪枝: 求解最优控制策略 μ^* 下状态 $\{q, b\}$ 的最优调度决策 $\mu^*((q, b))$ 时, 如果状态 $\{q, b\}$ 与对应的调度决策 u 满足 $\exists n \in \mathcal{N}, b_n = 0, q_n > 0, u_n = 0, m = \sum_{n \in \mathcal{N}} u_n < m_{\max}$, 同时式 (21) 成立, 则有 $\mu^*(q, b) \neq u$ 。

$$D_n \cdot q_n - (\omega_1 E_n^1 + \omega_2 E_n^2) > 0 \quad (21)$$

定理 2 表明, 在遍历所有策略寻找状态 $\{q, b\}$ 的最优策略的策略改进过程中, 对于满足定理 2 的策略, 应当直接予以排除, 不需要迭代计算其值函数。由此实现对决策空间的剪枝, 计算复杂度降低。

3 基于分析得到的最优算法

将定理 1、定理 2 的策略与标准的策略迭代算法 (Policy Iteration Algorithm, PIA) 相结合得到低复杂度的最优算法, 称为剪枝策略迭代算法 (Pruned Policy Iteration Algorithm, PPIA)。相较于标准的 PIA, PPIA 利用定理 1 和定理 2 对策略改进步骤中需要遍历的状态空间和决策空间进行剪枝。剪枝策略迭代算法伪代码如下:

输入: 系统参数, 状态空间 S , 决策空间 U , 转移概率矩阵 $\sum_{S' \in S} \Pr[S' | S, u]$, 一步成本 $g(q, u)$, 初始控制策略 μ, θ

输出: 最优控制策略 μ^*

```

1 初始化所有状态  $S \in S$  的值函数  $V(S) = 0$ 
2  $\delta = \theta$ 
3 while  $\delta \geq \theta$  do:
4   for  $S \in S$  do:
5      $v \leftarrow V(S)$ 
6      $V(S) \leftarrow g(S, \mu(S)) + \sum_{S' \in S} \Pr[S' | S, \mu(S)]$ 
7      $(V(S'))$ 
8      $\delta \leftarrow \max\{\delta, |v - V(S)|\}$ 
9   end
10 PolicyStable  $\leftarrow$  true
11 for  $S \in S$  do:
12   OldAction  $\leftarrow \mu(S)$ 
13   if 存在已遍历的状态  $S'$  满足定理 1 then:
14      $\mu(S) = \mu(S')$ 
15   else if  $S$  满足定理 2 then:
16      $\hat{U} = U$ 
17     for  $u \in U$  do:
18       If  $u$  满足定理 2 then:
19         将  $u$  从  $\hat{U}$  中移除
20     end
21      $\mu(S) \leftarrow \arg \min_{u \in \hat{U}} g(S, u) + \sum_{S' \in S} \Pr[S' | S, u]$ 
22    $(V(S'))$ 
23   else
24      $\mu(S) \leftarrow \arg \min_{u \in U} g(S, u) + \sum_{S' \in S} \Pr[S' | S, u]$ 
25    $(V(S'))$ 
26 end
27 If OldAction  $\neq \mu(S)$  then
28   PolicyStable  $\leftarrow$  false
29 end
30 if PolicyStable then 返回  $\mu^* = \mu$ 
31 else 回到第 3 行
```

算法第 2~9 行是策略验证步骤, 第 10~29 行是策略改进步骤。

从第 11 行开始以逆字典序遍历状态空间, 在第 13 行对满足定理 1 的状态 S 进行剪枝: 如果其衍生状态 S' 在本次策略改进步骤中已经被遍历, 则依照定理 1 将 $\mu(S')$ 直接作为 $\mu(S)$ 的解, 不再需要迭代求解, 由此实现对状态空间的剪枝。

从第 15 行开始, 遍历每个状态的决策空间以找寻最优决策, 在此处引入定理 2, 对于满足定理 2 的状态-决策组合 (State-action Combination) 可以直接跳过不进行遍历, 由此实现对决策空间的剪枝。

对于标准的 PIA, 需要遍历大小为 $|S|$ 的状态空

间和大小为 $|U|$ 的决策空间来求得 $\mu(S)$, 每次迭代的总复杂度为 $O(|S|^3 + |U||S|^2)$ 。PPIA 通过减少需要遍历的状态空间和决策空间大小, 使得其计算复杂度低于 PIA。由于采用了相同的迭代方法, PPIA 的最优性和可收敛性与 PIA 一致^[17]。

4 性能仿真与分析

4.1 仿真环境与设置

为体现所提算法的有效性, 设计进行仿真实验。实验基于 Win11 64 位系统, 使用 Matlab 仿真平台, 参数设置情况如下: 任务种类 $N=3$, 用户数量 $K=3$, 单个请求队列最多能容纳的请求数量 $q_{\max}=4$, 单用户单时隙最多同时卸载的同类请求数量 $r_{\max}=2$, 边缘服务器每个时隙能处理的任务种类上限 $m_{\max}=2$, 平均请求到达速率 0.9, 任务出生率 0.2, 死亡率 0.2, 计算能耗权重参数 $\omega_1=0.4$, 传输能耗权重参数 $\omega_2=0.4$, 迁移权重 $\omega_3=1$ 。请求到达速率和生灭变化特征 s_n^1 和 s_n^2 的分布特征分别建模如下: 请求到达速率的概率分布记作 P^r , 满足 $\sum_{i=1}^{r_{\max}} P^r(r_{n,k}=i)=1$; 生灭变化特征的概率分布记作 P^s , 满足 $P^s(s_n^1=0) + P^r(s_n^1=1)=1, P^s(s_n^2=1|s_n^1=1)=0, P^s(s_n^2=0|s_n^1=0) + P^s(s_n^2=1|s_n^1=0)=1, \forall n \in N$ 。

通信模型与计算模型相关参数配置情况如表 1 所示, 有限状态马尔可夫信道的信道增益 h_k 参考^[19]进行配置。

表 1 仿真参数配置
Tab. 1 Parameter settings

参数	值
高斯信道噪声方差 N_0/dB	8
系统总带宽 $B_{\text{total}}/\text{MHz}$	20
时隙长度 τ/s	1
有效开关电容 κ/C	1

从算法运行速度和调度策略的平均成本这两方面来进行仿真设计。作为对照的算法包括标准的 PIA 算法^[17]、同样基于动态规划但未考虑生灭特征的 SPIA 算法^[18]、随机策略、最长队列优先策略^[20], 以及基于本研究场景提出的启发式策略。启发式策略以队列负荷为标杆, 优先处理灭状态、队列负荷较高的任务请求。

4.2 算法运行时间分析

本小节与其他最优算法的运行时间进行对比, 运行时间越短说明算法复杂度更低、运行效率更高。

为体现优化理论的剪枝性能, 讨论能耗权重参数 ω_1 和 ω_2 的变化对不同算法运行时间的影响。实验结果如表 2 所示, PIA 和 SPIA 的运行时间受权重参数变化的影响较小, PPIA 的运行时间随能耗参数减小而减小。原因在于, 定理 2 的剪枝优化性能受具体的权重参数影响, 当能耗权重参数 ω_1 和 ω_2 增大时, 状态空间和决策空间中满足定理 2 中不等式条件的状态与决策数量增加, 可以剪枝处理掉的状态更多, 算法复杂度和运行时间随之降低。PIA 没有进行剪枝, SPIA 没有针对生灭过程进行剪枝, 因而运算时间长于 PPIA。PPIA 在 $\omega_1=0.4, \omega_2=0.4$ 时将运行时间缩短至 2.956 2 s, 相较于 PIA 算法有高于 26% 的效率提升。

表 2 系统的能耗权重参数 ω_1 和 ω_2 变化时不同算法所对应的运行时间差别

Tab. 2 Average computation time for different algorithms versus weight parameters

ω_1	ω_2	运行时间/s		
		PIA	SPIA	PPIA
0.4	0.4	4.001 4	3.905 8	2.956 2
0.4	0.7	3.970 1	3.913 4	3.108 7
0.4	1.0	4.124 4	4.027 0	3.342 0
0.7	0.4	3.916 6	3.832 4	3.077 8
0.7	0.7	4.113 2	3.900 7	3.379 3
0.7	1.0	4.204 6	4.076 5	3.528 1
1.0	0.4	4.148 0	4.014 6	3.223 5
1.0	0.7	4.176 7	3.953 3	3.455 7
1.0	1.0	4.098 9	3.994 1	3.342 0

为体现 PPIA 能在更复杂场景下保持性能优势, 讨论系统内任务请求种类数量的变化对不同算法运行时间的影响。实验结果如表 3 所示, 随着请求种类数量的上升, 系统复杂度与算法运行时间提高, 使用剪枝优化的 PPIA 始终保持 25% 以上的运行时间优势。

表 3 系统的任务请求种类数 N 变化时不同算法所对应的运行时间差别

Tab. 3 Average computation time for different algorithms versus types of requests

N	运行时间/s		
	PIA	SPIA	PPIA
3	4.001 4	3.905 8	2.956 2
4	81.921 0	77.560 0	61.357 0
5	1 705.600 0	1 680.200 0	1 112.700 0

综合以上两则实验场景可得, 以定理 2 为基础的剪枝算法 PPIA 能在保持最优性的同时相较于

PIA 算法和 SPIA 算法有着更快的运行速度, 在一定的能耗权重参数下表现更佳。

4.3 算法平均成本分析

本小节与其他次优算法的平均成本进行对比。为体现 PPIA 在不同系统负载下的平均成本优势, 比较平均请求到达速率变化对不同算法所对应的调度策略的平均成本的影响, 实验结果如图 2 所示。随着请求到达速率的提升, 更多的请求带来更多的时延、能耗成本, 平均成本呈上升趋势, 当到达速率大于 1.1 时趋于稳定, PPIA 的调度方案平均成本由 20.3839 上升至 26.740, 保持最低的同时在到达速率较高时体现出明显优势。启发式算法在到达速率低于 0.7 时性能表现相对优秀, 但当到达速率逐渐上升时与 PPIA 之间的差异明显增大。到达速率的提高带来了更高的队列负荷, 需要消耗更多的能耗成本进行处理或在节省能耗成本的同时面对更高的时延和迁移成本, PPIA 能准确权衡成本取舍, 同时通过迭代寻求最优解, 因而相较于其他次优算法表现良好。启发式算法能平衡队列负载, 但当请求到达速率较高时需要更高的能耗成本以保持队列负载平衡, 性能表现严重下降。

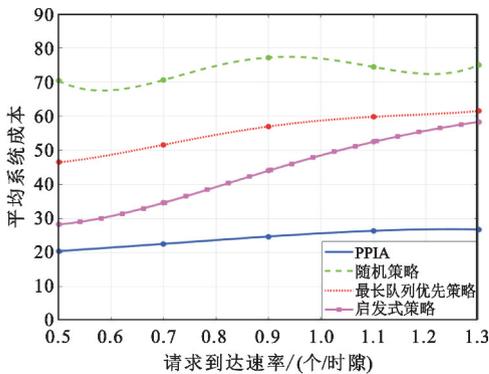


图 2 系统的请求到达速率变化时不同算法所对应的平均成本差异

Fig. 2 Average cost for different algorithms versus request arrival rate

为体现 PPIA 在不同生灭场景下能保持性能稳定, 比较任务死亡率变化对不同算法平均成本的影响, 实验结果如图 3 所示。随着任务死亡率的上升, 任务的平均激活周期变短, 请求数量下降导致调度方案的平均成本下降, 同时生灭频率的变化会让算法难以对请求的未来到达情况做出估计、降低算法性能的稳定性。在死亡率低于 0.4、任务生周期较长时, 最长队列优先策略和启发式策略难以在生状态判断是否应当积累请求等待后续处理, 同时难以

在灭状态判断是否应当等待下一次生状态再行处理, 因此综合性能表现差。基于生灭过程开发的 PPIA 能在不同生灭速率下准确判断未来状态的请求到达期望以取得最优性能表现, 平均成本保持在 30 以下。当死亡率较高时, 启发式算法的平均成本变化趋于稳定, 但仍然劣于 PPIA。

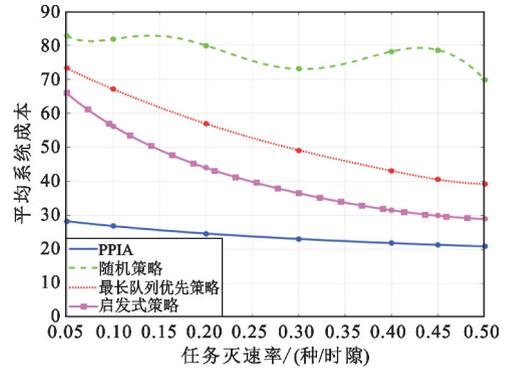


图 3 系统的任务死亡率变化时不同算法所对应的平均成本差别

Fig. 3 Average cost for different algorithms versus task death rate

综合以上两则实验场景可得, 启发式算法和最长队列优先算法在低到达速率、低死亡率等场景下性能表现不佳, PPIA 则能在不同系统条件下保持性能稳定, 平均成本低于其他次优算法。

5 结论

针对现有边缘计算研究未考虑任务生灭特征而存在复杂度瓶颈, 本文提出基于生灭过程和任务相关性感知的边缘计算模型并给出剪枝策略迭代算法, 利用任务的生灭特征对未来请求到达情况进行判断, 辅助确定当前状态最优决策以降低迭代过程中遍历的状态空间和决策空间大小。仿真结果表明, 基于生灭特征取得的优化定理使得所提算法突破了策略迭代的复杂度瓶颈, 计算开销低于标准策略迭代算法, 同时时延能耗成本低于最长队列优先策略等次优策略, 且能在多变的系统状态下保持性能稳定。

参考文献:

- [1] AL-SHUWAILI A, SIMEONE O. Energy-efficient resource allocation for mobile edge computing-based augmented reality applications [J]. IEEE Wireless Communications Letters, 2017, 6(3): 398-401.
- [2] CUI Y, HE W, NI C. Energy-efficient resource allocation for cache-assisted mobile edge computing [C]//

- Proceedings of 2017 IEEE 42nd Conference on Local Computer Networks. Singapore:IEEE,2017:640-648.
- [3] QU Y, DAI H, WANG L. Cotask: correlation-aware task offloading in edge computing [J]. World Wide Web, 2022, 25(5): 2185-2213.
- [4] 贾淑霞, 郝万明, 高梓涵, 等. 任务迁移的移动边缘计算系统中资源分配和任务卸载策略 [J]. 电讯技术, 2022, 62(8): 1037-1043.
- [5] MUNOZO M O, PASCUAL I A, VIDAL M J. Optimization of radio and computational resources for energy efficiency in latency-constrained application offloading [J]. IEEE Transactions on Vehicular Technology, 2014, 64(10): 4738-4755.
- [6] 许小龙, 方子介, 齐连永, 等. 车联网边缘计算环境下基于深度强化学习的分布式服务卸载方法 [J]. 计算机学报, 2021, 44(12): 2382-2405.
- [7] LIU C, ZHANG H, JI H. MEC-assisted flexible transcoding strategy for adaptive bitrate video streaming in small cell networks [J]. China Communications, 2021, 18(2): 200-214.
- [8] MECHALIKH C, TAKTAK H, MOUSSA F. Pureedgesim: a simulation toolkit for performance evaluation of cloud, fog, and pure edge computing environments [C]//Proceedings of 2019 International Conference on High Performance Computing & Simulation. Dublin:IEEE,2019:700-707.
- [9] CRAWFORD F W, MININ V N, SUCHARD M A. Estimation for general birth-death processes [J]. Journal of the American Statistical Association, 2014, 109(506): 730-747.
- [10] KLAIMI J, SENOUCI S M, MESSOUS M A. Theoretical game approach for mobile users resource management in a vehicular fog computing environment [C]//Proceedings of 2018 14th International Wireless Communications & Mobile Computing Conference. Limassol:IEEE,2018:452-457.
- [11] ARMBRUST M, FOX A, GRIFFITH R. A view of cloud computing [J]. Communications of the ACM, 2010, 53(4): 50-58.
- [12] CHEN Z, ZHU H, SONG L. Wireless multiplayer interactive virtual reality game systems with edge computing: modeling and optimization [J]. IEEE Transactions on Wireless Communications, 2022, 21(11): 9684-9699.
- [13] BURDT D, BRODERSEN R W. Processor design for portable systems [J]. Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology, 1996, 13(2/3): 203-221.
- [14] LIU B, LIU C, PENG M. Resource allocation for energy-efficient mec in noma-enabled massive iot networks [J]. IEEE Journal on Selected Areas in Communications, 2021, 39(4): 1015-1027.
- [15] HUANG P H, HSIEH F C, HSIEH W J. Prioritized traffic shaping for low-latency MEC flows in mec-enabled cellular networks [C]//Proceedings of 2022 IEEE 19th Annual Consumer Communications & Networking Conference. Las Vegas:IEEE,2022:120-125.
- [16] 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.
- [17] PUTERMAN M L. Markov decision processes: discrete stochastic dynamic programming [M]. New Jersey: John Wiley & Sons, 2014: 252-266.
- [18] ZHOU B, CUI Y, TAO M. Optimal dynamic multicast scheduling for cache-enabled content-centric wireless networks [J]. IEEE Transactions on Communications, 2017, 65(7): 2956-2970.
- [19] MOREIRA I, PIMENTEL C. Markov modeling of OFDM transmission over frequency selective channels [C]//Proceedings of 2017 40th International Conference on Telecommunications and Signal Processing. Barcelona: IEEE, 2017: 110-113.
- [20] GUMMADI R. Optimal control of a broadcasting server [C]//Proceedings of the 48th IEEE Conference on Decision and Control. Shanghai:IEEE,2009:2634-2639.

作者简介:

罗雨男, 1998 年生于重庆, 2020 年获工学学士学位, 现为硕士研究生, 主要研究方向为移动网络与边缘计算。

顾忆宵男, 1995 年生于湖北武汉, 2017 年获工学学士学位, 现为博士研究生, 主要研究方向为移动网络与边缘计算。

夏斌男, 1973 年生于湖南长沙, 2004 年获工学博士学位, 现为教授、博士生导师, 主要研究方向为无线通信与网络。