

面向用户的移动群智感知动态负载均衡任务分配策略

李凡, 吴亚辉, 邓苏, 马武彬, 周浩浩

引用本文

李凡, 吴亚辉, 邓苏, 马武彬, 周浩浩. 面向用户的移动群智感知动态负载均衡任务分配策略[J]. 计算机科学, 2026, 53(2): 379-386.

LI Fan, WU Yahui, DENG Su, MA Wubin, ZHOU Haohao. [Load Balancing Task Allocation Strategy for User-oriented Mobile Crowdsensing](#) [J]. Computer Science, 2026, 53(2): 379-386.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于贪心策略的区块链动态分片与跨分片交易协议优化](#)

Optimization of Blockchain Dynamic Sharding and Cross-shard Transaction Protocol Based on Greedy Strategy

计算机科学, 2025, 52(11A): 250100133-8. <https://doi.org/10.11896/jsjcx.250100133>

[灾害场景下基于SDN和无人机辅助的无线边缘存储系统性能优化方法](#)

Performance Optimization of Wireless Edge Storage System Based on SDN and Drone Assistance in Disaster Scenarios

计算机科学, 2025, 52(11): 306-319. <https://doi.org/10.11896/jsjcx.240900004>

[基于卷积双延迟深度确定性策略梯度的卫星网络多路路径路由算法](#)

Multipath Routing Algorithm for Satellite Networks Based on Convolutional Twin Delay Deep Deterministic Policy Gradient

计算机科学, 2025, 52(11): 280-288. <https://doi.org/10.11896/jsjcx.240800161>

[基于申威编译器的并行调度策略优化技术研究](#)

Research on Parallel Scheduling Strategy Optimization Technology Based on Sunway Compiler

计算机科学, 2025, 52(9): 137-143. <https://doi.org/10.11896/jsjcx.241200072>

[基于微分方程的失联潜水器轨迹预测模型算法研究](#)

Study on Trajectory Prediction Model Algorithm of Missing Submersible Based on DifferentialEquation

计算机科学, 2025, 52(6A): 240900071-9. <https://doi.org/10.11896/jsjcx.240900071>

面向用户的移动群智感知动态负载均衡任务分配策略

李凡 吴亚辉 邓苏 马武彬 周浩浩

国防科技大学信息系统工程重点实验室 长沙 410073

(lifan23@nudt.edu.cn)

摘要 移动群智感知系统中,用户的参与意愿和体验对系统的整体性能和长期持续运行具有重要影响。现有面向用户的任务分配策略大多只考虑到用户的成本效益,忽视了任务分配过程的负载均衡问题,致使部分关键节点因负载较重而过早退出,影响系统的长期效能。为此,构建了一种以用户为中心的长时域动态任务分配模型,针对模型的动态性和持续性的特点,提出了基于改进 Lyapunov 优化理论的求解算法,同步考虑了系统整体效益和负载均衡性的双重优化,实现动态环境下的带有负载均衡约束的任务最优的分配。实验结果表明,所提算法在保证队列稳定性和系统整体效益最优的前提下,将用户的负载均衡性提升了近 20%。

关键词: 移动群智感知;负载均衡;Lyapunov 优化理论;系统整体效益

中图分类号 TP301

Load Balancing Task Allocation Strategy for User-oriented Mobile Crowdsensing

LI Fan, WU Yahui, DENG Su, MA Wubin and ZHOU Haohao

National Key Laboratory of Information Systems Engineering, National University of Defense Technology, Changsha 410073, China

Abstract In mobile crowdsensing systems, the user's participation intention and experience have an important impact on the overall performance and long-term sustainable operation of the system. Most existing user-oriented task allocation strategies only consider the cost-benefits of users and ignore the load balancing issue in the task allocation process, resulting in the premature exit of some key nodes due to heavy loads, which affects the long-term performance of the system. Therefore, this paper proposes a user-centered, long-time dynamic task allocation model. Aiming at the dynamics and persistence of the model, a solution algorithm based on improved Lyapunov optimization theory is proposed, which simultaneously considers the dual optimization of overall system benefits and load balancing, achieving optimal task allocation with load balancing constraints in dynamic environments. Experimental results demonstrate that the proposed algorithm improves the load balancing of users by nearly 20% under the premise of ensuring queue stability and optimal overall system benefits.

Keywords Mobile crowdsensing, Load balancing, Lyapunov optimization theory, Overall system benefits

1 引言

随着移动通信网络与智能终端设备的日益迅速发展,移动群智感知(Mobile Crowdsensing, MCS)成为一种具有巨大潜力的新型感知模式。MCS 系统通常由任务请求者、感知平台以及配备终端载体的用户组成,终端设备包括摄像头、麦克风、GPS 等高性能的传感器,能够对复杂的数据进行感知、收集和^[1]处理。与传统的感知模式相比, MCS 具有低成本、高精度以及更广的覆盖等优势^[2],在智慧城市^[3]、环境监测^[4]、智能交通^[5]、公共安全^[6]等领域得到了一定的应用。

MCS 是一种弹性可扩展的感知框架,用户可自由加入和退出系统,因此,其相对于传统的传感器网络,管理和使用

难度更大,面临许多挑战性问题。其中的一个重要挑战就是任务分配问题。当前的任务分配策略多侧重于效益优化,忽略了用户任务分配的均衡性,导致关键节点分配的任务量也更大。因此,关键节点往往因资源耗尽而过早退出系统,导致参与周期缩短,整体任务完成效率降低,不利于 MCS 系统的长期稳定运行。另一方面,围绕任务负载均衡分配的问题,文献^[7]提出了一种面向离线环境的负载均衡任务分配算法。该算法虽然提升了系统整体效益,但缺乏灵活性和适应性,未能应对复杂的动态环境。文献^[8]考虑了动态环境下的负载均衡问题,但忽略了系统整体效益,导致感知成本的损失较大。总体来说,现有文献大多考虑均衡性或效益优化的单个方面,很少考虑二者的同步优化。因此,在 MCS 中亟需综合

到稿日期:2024-11-29 返修日期:2025-06-30

基金项目:国家自然科学基金面上项目(61871388)

This work was supported by the General Program of National Natural Science Foundation of China(61871388).

通信作者:吴亚辉(wuyahui@nudt.edu.cn)

考虑系统整体效益和动态负载均衡的优化策略。

针对上述问题,本文提出了一种基于 Lyapunov 优化理论的动态负载均衡算法(Lyapunov-based Dynamic Load Balancing, LDLB)。相较于其他方法, Lyapunov 优化理论所需的先验知识少且具备强大的解耦能力,能依据系统实时的运行状态进行在线决策,将复杂的系统近似转换为相对独立的子问题并行求解,避免陷入局部最优解。此外,在动态环境下,系统中的参数时刻处于变化状态, Lyapunov 优化理论具有动态、自适应的特性,能够实时监测系统状态的波动,调整决策变量,确保任务分配能够及时适应环境变化。实验验证了 LDLB 算法能够实时动态调整任务分配过程,在确保任务队列稳定性和系统整体效益最优的同时,优化用户的负载均衡性指标,提升资源利用率,有利于系统的长期持续运行。

2 相关工作

如前所述, MCS 系统的核心架构包括任务请求者、感知平台及配备智能终端的用户。任务请求者向感知平台发布任务需求,平台根据任务分配策略筛选相关用户执行任务,用户通过智能终端收集数据,并将结果上传至平台,随后平台将整合后的数据返回给信息任务请求者。MCS 系统模型的基础框架如图 1 所示。

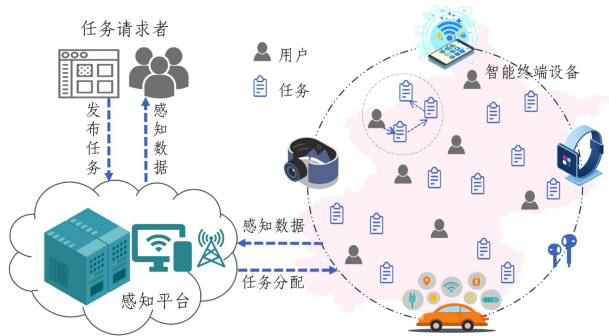


图 1 MCS 系统模型

Fig. 1 Mobile crowdsensing system model

任务分配是 MCS 的关键问题之一,核心在于如何实现用户与任务的有效匹配。这通常需要综合考量任务属性(如任务复杂度、时空要求等)、平台利益(如成本控制、服务质量等)以及用户能力与偏好(如资源限度、兴趣偏好等)。

为了满足用户的多样化需求,提升用户的参与体验, Wu 等^[9]提出了个性化任务推荐系统,考虑用户偏好和可靠性的细粒度特征,实现用户任务的最佳匹配。Gao 等^[10]从用户感知任务的距离和对任务的偏好角度出发,基于用户的参与成本建模,并致力于最小化该成本。进一步地,考虑到平台和用户效益的双重优化问题, Simon 等^[11]提出了一种结合匹配理论与在线强化学习的去中心化算法,考虑平台和用户间的利益冲突,引入自由感知机制,加速用户的学习过程,减少任务分配过程的冲突。Zhang 等^[12]以最大化任务完成数量为目标,提出了一种基于模糊控制的多任务分配算法,综合考虑用户和任务的时空特征,实现

任务的合理分配。

用户公平性不仅包括成本公平,还涵盖了资源公平、负载均衡公平等多个维度。针对 MCS 中的成本公平任务分配问题, Sun 等^[13]提出一种贪心算法,将到达平台的任务尽可能成本均衡地分配给用户,保障用户间的公平性。Li 等^[14]建立公平模型来衡量用户执行任务的价值,并提出一种基于博弈论的任务分配算法,目标是在一定公平程度内最大化用户收入。对于用户资源受限的 MCS 系统,任务分配不仅要考虑感知成本与用户效用,还应重视用户的负载承受能力。Song 等^[15]研究了距离约束下的公平任务分配问题,同时考虑用户及任务发布者的利益,提出具有距离约束的公平任务分配策略。An 等^[16]聚焦于负载均衡的用户招募问题,目标是 minimized 招募用户的最大感知成本,确保所有任务能由被选择的用户完成,这种策略对于资源受限的用户更友好。Wang 等^[17]提出了一种双延迟深度随机策略梯度方法,在保证负载均衡和减少用户移动成本的同时,缩短了任务完成时延。Meitei 等^[7]提出离线环境下的负载均衡任务分配算法,在最小化负载均衡项的同时分配更多的任务,但对于复杂动态场景存在局限性。Bajaj 等^[8]构建了基于用户设备资源丰富度的模型,并提出了两种负载均衡算法——贪婪算法(NV-Greedy)和加权随机算法(NV-Weighted),将任务分配给参与者的子集,延长 MCS 系统和用户的生命周期。但是,该算法未充分考虑用户成本效益消耗的问题。

学者 Lyapunov 首次提出了一种基于状态矢量的系统稳定性理论,并给出稳定性判定的依据。在此基础上, Neely^[18]进一步发展了 Lyapunov 随机优化技术。近年来, Lyapunov 优化方法被应用于解决动态 MCS 系统中的优化问题。Song 等^[15]构建基于 Lyapunov 优化技术的双队列优化模型,保证用户和平台的公平性,并引入模拟退火算法迭代寻找最优解。Luan 等^[19]提出一种基于边缘的 MCS 的感知数据卸载策略,设计双队列 Lyapunov 优化函数,在保持系统稳定性的同时最小化数据卸载成本。面对现实场景中参与者的自私合理性, Duan 等^[20]将 Lyapunov 优化与稳定控制方案相结合,提出一种公平感知任务分配策略,旨在最大化社会福利函数,并通过比例公平原则来维持网络稳定性。针对动态 MCS 系统中位置感知和位置多样性问题, Wang 等^[21]提出了一种带扰动参数的 Lyapunov 算法,解决了不连续覆盖和工人公平分配问题,确保系统的稳定性,并实现了接近最优的时间平均感知效用。针对机会 MCS 系统中感知信息质量和传输调度的协同优化问题, Guo 等^[22]构建基于 Lyapunov 优化函数的随机网络优化框架,在保持系统稳定性的同时最大化系统的效用。Chang 等^[23]提出一种基于 Lyapunov 优化的在线能量均衡策略,并结合线性规划与遗传算法进行求解,目标是最大化系统的效用。

目前,以用户为中心的任务分配通常侧重于成本优化,对任务负载均衡的优化相对匮乏。部分研究方案难以兼顾负载均衡和系统整体效益,甚至在部分场景下牺牲了整体效益,不利于 MCS 系统的长期稳定发展。鉴于此,本文致力于解决动

态系统中任务队列的最优控制问题,具体贡献如下:

- 1) 构建了一个以用户为中心的长时域动态任务分配模型,融合了系统整体效益和负载均衡条件,实现同步优化。
- 2) 针对上述模型的动态性和时序性特点,提出一种基于改进 Lyapunov 方法的动态负载均衡算法(LDLB)。
- 3) 通过仿真实验,验证了 LDLB 算法的有效性。其在确保队列稳定性和系统整体效益最优的前提下,将用户的负载均衡性提升了近 20%。

3 移动群智感知动态任务分配模型

3.1 问题描述

本文中使用的符号和含义如表 1 所列。

表 1 符号及定义

Table 1 Symbols and their definition

符号	含义
M	任务集 i
N	用户集 j
m, n	任务和用户的数量
t	时隙 $t \in \{0, 1, 2, \dots\}$
$x_{ij}[t]$	是否将任务 i 分配给用户 j
λ	任务到达平台的速率
$Q(t)$	时隙 t 用户的任务队列积压向量
$Q_j(t)$	时隙 t 用户 j 的任务队列积压值
Q_{\max}	任务队列积压最大阈值
\bar{Q}_t	时隙 t 的平均任务队列积压
$b_j(t)$	用户 j 的任务处理能力
$B(t)$	任务队列积压
D	任务队列积压方差
$U(t)$	时隙 t 内感知平台的效益
\bar{U}	感知平台的时间平均效益
$c_{ij}(t)$	用户 j 完成任务 i 的感知成本
$C(t)$	时隙 t 内用户的感知成本
\bar{C}	用户的时间平均感知成本
$W(t)$	时隙 t 内的系统整体效益
\bar{W}	时间平均系统整体效益

考虑一个 MCS 系统模型,定义模型中的任务集为 \mathcal{M} ,用户集为 \mathcal{N} ,共有 m 个感知任务和 n 个用户,任务和用户有初始的位置坐标。将时间划分为离散的等长的 t 时隙, $t \in \{0, 1, 2, \dots\}$ 。在每个时隙 t ,任务持续到感知平台,且到达数量是独立同分布的,满足参数为 λ 的泊松分布。用 $x_{ij}[t]$ 表示时隙 t 的任务分配情况,若任务 i 分配给用户 j ,记为 $x_{ij}[t]=1$,否则记为 $x_{ij}[t]=0$ 。每个任务在时隙 t 中只能被执行一次,即任务是不可分割的,但一个用户 j 在时隙 t 内可以被分配多个不同任务,总数为 $\sum_{i=1}^m x_{ij}(t)$ 。

$Q(t) = (Q_1(t), Q_2(t), \dots, Q_n(t))$ 表示时隙 t 用户的任务队列积压向量。用户 j 的任务队列积压动态变化公式如下:

$$Q_j(t+1) = \max[Q_j(t) - b_j(t), 0] + \sum_{i=1}^m x_{ij}(t) \quad (1)$$

其中,用户 j 的初始任务队列积压 $Q_j(0) = 0$; $b_j(t)$ 为用户 j 的任务处理能力,对于所有用户, $b_j(t)$ 是一个有限的常数,即存在 b_{\max} ,使得对所有的 $b_j(t)$,都满足 $0 \leq b_j(t) \leq b_{\max}$ 。本文动态任务分配模型如图 2 所示,反映了用户任

务队列积压的更新过程。




图 2 动态任务分配模型

Fig. 2 Dynamic task allocation model

由 Lyapunov 优化理论^[16]可知,当用户的队列积压 $Q_j(t)$ 满足:

$$\limsup_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}\{Q_j(t)\} < \infty \quad (2)$$

则 $Q_j(t)$ 是稳定的。且存在最大阈值 Q_{\max} ,对于所有 $Q_j(t)$ 都有 $Q_j(t) \leq Q_{\max}$ 。

3.2 负载均衡条件

$B(t)$ 用于衡量时隙 t 队列的负载均衡性:

$$B(t) = \sum_{j=1}^n |Q_j(t) - \bar{Q}_t| \quad (3)$$

其中, $\bar{Q}_t = \frac{1}{n} \sum_{j=1}^n Q_j(t)$ 表示在时隙 t 的平均队列积压。 $B(t)$ 的值越小,用户间的任务队列积压差异越小,负载均衡性越好。

3.3 系统整体效益

时隙 t 内感知平台的效益记为 $U(t)$,其大小取决于用户的任务完成数量。

$$U(t) = \sum_{i=1}^m \sum_{j=1}^n x_{ij}[t] \quad (4)$$

时隙 t 内用户总的感知成本记为 $C(t)$,以用户执行任务时的移动距离来进行衡量。

$$C(t) = \sum_{i=1}^m \sum_{j=1}^n c_{ij} \cdot x_{ij}[t] \quad (5)$$

其中, c_{ij} 表示任务 i 和用户 j 之间的距离。对于经纬度坐标,需考虑地球的球形特质,本文用 Haversine 公式计算坐标间的最短距离。

将平台效益和用户成本间的差值定义为系统整体效益,记为 $W(t)$:

$$W(t) = U(t) - C(t) \quad (6)$$

3.4 目标函数

由于该系统模型随时隙 t 动态变化且具有非线性和不确定性,因此,本文考虑时间平均约束下的系统整体效益优化,记为 \bar{W} :

$$\bar{W} = \bar{U} - \bar{C} = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}\{U(t) - C(t)\} \quad (7)$$

该模型的目标函数如下:

$$\max \bar{W} \quad (8)$$

$$\text{s. t. } x_{ij}[t] \in \{0, 1\} \quad (9)$$

$$\sum_{j=1}^n x_{ij}(t) \leq 1, 0 \leq i \leq m \quad (10)$$

$$\limsup_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}\{Q_j(t)\} < \infty \quad (11)$$

其中,目标为最大化时间平均下系统整体效益。约束(9)表明 $x_{ij}[t]$ 的值只能为 0 或 1,约束(10)为任务的不可分割性,约束(11)确保了任务队列的稳定性。

4 负载均衡任务分配策略

4.1 理论模型

Lyapunov 优化理论是一种动态且具备自适应特性的算法框架。根据文献[18],定义一般的 Lyapunov 优化函数为:

$$L(t) = \frac{1}{2} \sum_{j=1}^n Q_j^2(t) \quad (12)$$

本文模型考虑到任务队列均衡性的优化,将式(3)的负载均衡项引入式(12),改进后的 Lyapunov 函数如下:

$$L(t) = \frac{1}{2} \sum_{j=1}^n Q_j^2(t) + \frac{1}{2} \sum_{j=1}^n (Q_j(t) - \bar{Q}(t))^2 \quad (13)$$

其中,可将 $|Q_j(t) - \bar{Q}|, j \in \mathcal{N}$ 视为一个新的队列积压向量。

定义两个相邻时隙间 $L(t)$ 的期望变化值为 Lyapunov 漂移函数:

$$\Delta L(t) = \mathbb{E}\{L(t+1) - L(t) | Q(t)\} \quad (14)$$

将系统整体效益 $W(t)$ 作为惩罚项纳入式(14)的漂移函数中,得到的漂移惩罚函数如下:

$$\Delta_V(Q(t)) = \Delta L(t) - V \cdot \mathbb{E}\{W(t) | Q(t)\} \quad (15)$$

其中, V 是一个非负权重参数。改变 V 值大小可以调整队列稳定均衡性和系统整体效益间的优化权重。

接下来证明漂移惩罚函数的有界性。

定理 1 (漂移惩罚上界) 在每个时隙 t , 对于给定的参数 $V > 0$, 在任何可行的控制决策下, 漂移惩罚函数均满足:

$$\Delta_V(Q(t)) \leq A - 2Q_j(t)(b_j(t) - \sum_{i=1}^m x_{ij}[t]) - V \cdot (\sum_{i=1}^m \sum_{j=1}^n (1 - c_{ij}) \cdot x_{ij}[t]) \quad (16)$$

其中, $A = \sum_{j=1}^n n^2 + (b_{\max})^2 + 2Q_{\max}^2$ 。

证明 首先, 对任意 $x \geq 0, y \geq 0, z \geq 0$ 都存在 $(\max[x - y, 0] + z^2) \leq x^2 + y^2 + z^2 - 2x(y - z)$, 且已知 $0 \leq b_j(t) \leq b_{\max}, 0 \leq Q_j(t) \leq Q_{\max}$, 则有:

$$\begin{aligned} Q_j^2(t+1) - Q_j^2(t) &\leq (b_j(t))^2 + (\sum_{i=1}^m x_{ij}[t])^2 - \\ &2Q_j(t)(b_j(t) - \sum_{i=1}^m x_{ij}[t]) \\ &\leq (b_{\max})^2 + n^2 - 2Q_j(t)(b_j(t) - \\ &\sum_{i=1}^m x_{ij}[t]) \end{aligned} \quad (17)$$

平均队列积压 $\bar{Q}(t)$ 受到 $Q_j(t)$ 上界的限制, 即有 $0 \leq \bar{Q}(t) \leq Q_{\max}$, 结合式(17), 得:

$$\begin{aligned} (Q_j(t+1) - \bar{Q}(t+1))^2 - (Q_j(t) - \bar{Q}(t))^2 &\leq n^2 + \\ (b_{\max})^2 - 2Q_j(t)(b_j(t) - \sum_{i=1}^m x_{ij}[t]) &+ 4Q_{\max}^2 \end{aligned} \quad (18)$$

$$\begin{aligned} -V \cdot \mathbb{E}\{\sum_{j=1}^n W(t) | Q(t)\} &= -V \cdot \mathbb{E}\{\sum_{i=1}^m \sum_{j=1}^n (1 - c_{ij}) \cdot \\ x_{ij}[t] | Q(t)\} \end{aligned} \quad (19)$$

对式(17)和式(18), 在 $j \in \{1, 2, \dots, n\}$ 上求和并取期望, 再乘系数 $1/2$ 后两边加上式(19), 化简得:

$$\begin{aligned} \Delta_V(Q(t)) &\leq A - 2Q_j(t)(b_j(t) - \sum_{i=1}^m x_{ij}[t]) - V(\sum_{i=1}^m \sum_{j=1}^n (1 - \\ c_{ij}) \cdot x_{ij}[t]) \end{aligned} \quad (20)$$

定理 1 得证。

4.2 问题转换

为了最大化系统整体效益的同时, 优化队列的均衡性和稳定性指标, 将本文的优化目标转换为最小化式(20)上界。在感知平台内能实时监测到 $Q_j(t)$ 的值, 且 $b_j(t)$ 已知, 故只需求解式(21):

$$\arg \min_{j \in \mathcal{N}} \mathbb{E}\{\sum_{i=1}^m \sum_{j=1}^n (2Q_j(t) - V(1 - c_{ij})) \cdot x_{ij}[t]\} \quad (21)$$

4.3 算法描述

本文设计了一种基于 Lyapunov 理论的动态负载均衡算法(LDLB), 如算法 1 所示。

首先进行初始化, 输入时隙长度 T 、用户集 \mathcal{M} 和任务集 \mathcal{N} , 定义用户的任务执行能力 $b_j(t)$ 的值。在 $t=0$ 时, 所有任务队列积压值为 0。其中, 对于任务 $i \in \mathcal{M}$, 在时隙 t 中, 找到一个 $j^* = \arg \min_{j \in \mathcal{N}} 2Q_j(t) - V(1 - c_{ij})$ (第 2-3 行)。当 $2Q_j(t) - V(1 - c_{ij}) \leq 0$ 时, 在时隙 t , 任务 i 被分配给用户 j^* , 记为 $x_{ij^*}[t] = 1$, 否则记为 $x_{ij^*}[t] = 0$ (第 4-7 行)。同时, 对于其他的用户 $j \in \mathcal{N} - j^*$, 同样记为 $x_{ij}[t] = 0$ (第 8 行)。遍历平台中的所有任务, 完成时隙 t 内的任务分配。

算法 1 LDLB 算法

输入: $T, \mathcal{M}, \mathcal{N}, b_j(t), Q_j(t)$

输出: $j^*, x_{ij^*}[t]$

1. Set $Q_j(0) = 0, j \in \mathcal{N}$
2. For $i \in \mathcal{M}$ do
3. Find $j^* \in \mathcal{N}$ makes $j^* = \arg \min_{j \in \mathcal{N}} 2Q_j(t) - V(1 - c_{ij})$
4. If $2Q_j(t) - V(1 - c_{ij}) \leq 0$ then
5. Set $x_{ij^*}[t] = 1$;
6. Else
7. Set $x_{ij^*}[t] = 0$;
8. For other users $j \in \mathcal{N} - j^*$, set $x_{ij}[t] = 0$;
9. Update $Q_j(t)$

4.4 算法性能分析

为进一步验证 LDLB 算法的最优性, 对队列稳定性和系统效益性能进行严格的理论证明。

定理 2 (队列稳定性) 该算法在引入负载均衡条件后, 得到的可行解仍能保证任务队列的稳定性。

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}\{Q_j(t)\} \leq \frac{A'}{2\delta} \quad (22)$$

其中, $A' = A - V(W_{\max} - W_{\min})$ 。

证明 首先由文献[18]中的 ω -only 策略最优性和任意 ω -only 策略得: 对于任意的 $\delta > 0$, 在时隙 t 内有:

$$\mathbb{E}\{W(t)\} \geq W_{\text{opt}} - \delta \quad (23)$$

$$\mathbb{E}\{b_j(t)\} \geq \mathbb{E}\{\sum_{i=1}^m x_{ij}[t]\} + \delta \quad (24)$$

其中, W_{opt} 表示可行解中最优的系统整体效益值, 有 $W_{\min} \leq W_{\text{opt}} \leq W_{\max}$ 。

将式(23)和式(24)代入式(20)中化简得:

$$\begin{aligned} \Delta L(t) + 2\delta \sum_{j=1}^n \mathbb{E}\{Q_j(t)\} \\ \leq A - V \mathbb{E}\{W_{\text{opt}} | Q(t)\} + V \cdot \mathbb{E}\left\{\sum_{j=1}^n W(t) | Q(t)\right\} \\ \leq A - V(W_{\text{max}} - W_{\text{min}}) \end{aligned} \quad (25)$$

记 $A' = A - V(W_{\text{max}} - W_{\text{min}})$, 则有:

$$\Delta L(t) \leq A' - 2\delta \sum_{j=1}^n \mathbb{E}\{Q_j(t)\} \quad (26)$$

结合式(14)对 t 从 0 到 $T-1$ 求和, 且已知 $L(0) = 0$,

$L(T) \geq 0$, 得:

$$2\delta \mathbb{E}\left\{\sum_{t=0}^{T-1} \sum_{j=1}^n Q_j(t)\right\} \leq T \cdot A' \quad (27)$$

两边化简移项后取 $T \rightarrow \infty$, 得:

$$\lim_{T \rightarrow \infty} \frac{1}{T} \sum_{t=0}^{T-1} \mathbb{E}\{Q_j(t)\} \leq \frac{A'}{2\delta} \quad (28)$$

定理 2 得证。

定理 3 (系统效益性能) 该算法求得的时间平均系统整体效益值有下界。

$$\bar{W} \geq W_{\text{opt}} - \frac{A}{V} \quad (29)$$

其中, $A = \sum_{j=1}^n n^2 + (b_{\text{max}})^2 + 2Q_{\text{max}}^2$ 。

证明 已知 $\forall j \in N, \mathbb{E}\{Q_j(t)\} \geq 0$ 。对式(15)取期望, 并联立式(20)、式(23)、式(24)得:

$$\begin{aligned} \mathbb{E}[\Delta L(t)] - V \cdot \mathbb{E}\{W(t) | Q(t)\} \leq A - V \mathbb{E}\{W_{\text{opt}} | Q(t)\} + \\ 2 \mathbb{E}\left\{\sum_{i=1}^m \sum_{j=1}^n (x_{ij}[t] - b_j(t)) Q_j(t)\right\} \leq A - V W_{\text{opt}} \end{aligned} \quad (30)$$

结合式(14)得:

$$\mathbb{E}[L(t+1) - L(t)] \leq A - V W_{\text{opt}} + V \cdot \mathbb{E}\{W(t) | Q(t)\} \quad (31)$$

将式(31)对 t 由 0 到 $T-1$ 求和, 取 $T \rightarrow \infty$, 且已知 $L(0) = 0, L(T) \geq 0$, 化简得:

$$\lim_{T \rightarrow \infty} \sum_{t=0}^{T-1} \mathbb{E}\{W(t)\} \geq W_{\text{opt}} - \frac{A}{V}$$

定理 3 得证。

5 实验仿真与结果分析

为验证所提算法的有效性, 实验采用微软亚洲研究院发布的 GeoLife 数据集^[24]进行仿真。该数据集涵盖了 182 名用户的 17621 条活动轨迹, 每条轨迹包含带有时间标签的位置节点, 在相关的仿真实验中被广泛采用。实验采用固定的随机种子, 并进行 100 次独立随机重复实验取平均值, 以消除随机偏差, 充分描述所提算法的性能。

本算法的编程语言为 Python 3.8.10, 开发环境为 PyCharm 2023。实验运行环境为 AMD Ryzen 5 4600U with Radeon Graphics @ 2.10 GHz, 16 GB 运行内存, Windows 11 64 位操作系统。

5.1 对比实验

首先, 为验证算法的性能, 将提出的 LDLB 算法与以下两种典型任务分配算法进行比较。1) 当前具有代表性的动态任务分配算法——DTA, 其与 LDLB 算法的不同点在于未考虑用户的负载均衡性, 主要用于验证本文算法的整体效益未受

到损失。2) 一种具有代表性的动态负载均衡算法——NV-Greedy^[15], 该算法是一种贪婪算法, 在每个时隙将任务分配给所需任务数量最富有的用户, 即能者多劳, 主要用于全方位对比本文算法的效果。

下面对 3 种算法的系统整体效益、队列稳定性和负载均衡性指标进行对比。参数设置如表 2 所列, 其中 V 的取值参考 5.2 节的实验。本文实验运行 1000 个时隙。

表 2 参数设置

Table 2 Parameters setting

参数	取值
λ	30
n	10
$b_j(t)$	[3,5]
V	30000
t	{0,1,...,999}

图 3 和图 4 分别展示了感知平台效益和用户感知成本随时间 t 的变化。可以看出, 在所有时隙内, LDLB 算法和 DTA 算法的平台效益和用户成本在初期都呈上升趋势, 且随时隙推移逐渐稳定。NV-Greedy 算法的平台效益最高, 但用户成本却远超出其他两种算法, 且波动范围大。导致该现象的原因在于: NV-Greedy 算法只考虑用户任务分配的均衡性, 不计感知成本, 所有到达平台的任务都将被分配; 而 LDLB 算法和 DTA 算法基于 Lyapunov 理论进行求解, 将到达平台的任务进行初步筛选后再分配。即用户成本高于预期的任务, 在该时隙不予分配, 直至出现符合预期的用户。




图 3 感知平台效益对比

Fig. 3 Comparison of benefits of MCS platform




图 4 用户感知成本对比

Fig. 4 Comparison of task allocation costs

图 5 显示了系统整体效益随时隙变化的情况。可以看出, LDLB 算法和 DTA 算法的系统整体效益远高于 NV-Greedy 算法, 且变化范围小、状态相对稳定。前面实验已经分析出, NV-Greedy 算法在任务分配时没有考虑用户成本, 即

使平台效益对比其他两种算法占优势,其整体效益仍不如其他算法。




图5 系统整体效益对比

Fig. 5 Comparison of overall system benefits

图6展示了用户数量变化对3种算法的平均系统整体效益 \bar{W} 的影响。实验中设置用户数量为10~50,其他参数保持不变。由图6的结果可以看出:LDLB算法和DTA算法随着用户数量的增加, \bar{W} 先上升后趋于稳定,说明其在任务分配上是有效的;而NV-Greedy算法未呈现明显的变化趋势, \bar{W} 始终保持在较低水平。




图6 用户数量对平均系统整体效益的影响

Fig. 6 Impact of user numbers on average overall system benefits

3.2节中已给出任务队列积压 B 和平均队列积压 \bar{Q}_i 的含义,为便于分析,这里引入队列积压方差 D :

$$D = \frac{1}{n} \sum_{j=1}^n (Q_j(t) - \bar{Q}_i)^2 \quad (33)$$

将求 B 转换为求 D 。易证 D 和 B 的值是呈正相关的, D 的大小可以反映任务队列的负载均衡性。3种算法的平均队列积压和队列积压方差随时隙的变化如图7和图8所示。




图7 平均队列积压对比

Fig. 7 Comparison of average queue backlog

图7的结果显示,3种算法的平均队列积压 \bar{Q}_i 的差距不大,都在稳定值上下小幅度波动。这反映了3种算法能避免

队列积压随着时间的推移而无限增大,保证了队列的稳定性,是系统长期稳定运行的关键所在。图8的结果显示,LDLB算法的队列积压方差 D 显著低于两种对比算法,即任务负载均衡性更优。这是由于该算法能够将任务更加均匀地分布在用户队列中,提高系统资源的利用率。相比其他算法,LDLB算法将负载均衡性分别提升了19.44%和19.29%。




图8 队列积压方差对比

Fig. 8 Comparison of queue backlog variance

5.2 V值对系统的影响

V 值在Lyapunov优化中有重要的权重,为进一步探究不同 V 值对系统整体效益、平均队列积压和队列积压方差的影响程度,设置 $V = \{1, 10, 100, 1000, 5000, 10000, 15000, 20000, 25000, 30000\}$,实验共运行1000个时隙,实验结果如图9—图11所示。

图9展示了不同 V 值对平均系统整体效益 \bar{W} 的影响。由结果可以看出:随着 V 值增大, \bar{W} 呈上升趋势; V 值小于5000时, \bar{W} 增幅显著,之后减小并逐渐趋于稳定。上述现象是由式(20)决定的,且与定理3的结论相一致。 V 值增大,本文策略对系统整体效益最大化目标的重视程度也随之提高,平台倾向于将任务分配给能使系统整体效益达到最大的用户。因此,当没有满足条件的用户可以匹配时,任务将暂留在感知平台中,直至后续时隙中出现最佳的匹配机会。此时,队列积压值也会相应降低,这一点在图10中得到了进一步验证。




图9 不同V值下平均系统整体效益的变化

Fig. 9 Changes in average overall system benefits under different V values

图10的结果显示,在不同的 V 值下,平均队列积压 \bar{Q}_i 在初期迅速达到稳定状态,且随 V 值增大, \bar{Q}_i 逐渐降低。这与定理2的结论一致。具体而言, V 值增大,式(22)的右边项 $A'/2\delta$ (其中 $A' = A - V(W_{\max} - W_{\min})$)减小,故而限制了队列

积压长度。需要注意的是,实验设置的任务到达率和用户数量较小,且任务处理能力与其适中匹配。因此,任务队列不会过度累积,且能够迅速收敛至稳定值。在现实 MCS 场景中,需考虑系统内部结构的复杂性,确保系统在不超负荷的情况下运行,保证任务队列的稳定性。




图 10 不同 V 值下平均队列积压的变化

Fig. 10 Changes in average queue backlog under different V values

图 11 展示了不同 V 值下队列积压方差的变化。由结果可以看出:对于所有 V 值,队列积压方差 D 都不会随着时隙变化而无限增大,而是迅速收敛于固定值附近;随着 V 值增大, D 的稳定区间和波动范围均降低,任务队列间的差异减小,任务负载均衡性增强;在 $V=30\,000$ 时,系统的整体效益最大,且队列的负载均衡最优。




图 11 不同 V 值下队列积压方差的变化

Fig. 11 Changes in queue backlog variance under different V values

通过以上实验,验证了基于 Lyapunov 优化理论的动态负载均衡算法的有效性。该算法在维持用户队列稳定性和系统整体效益最优的情况下,降低了用户间的负载差异,改善了用户任务分配数量不均的问题,且通过调整 V 值能使系统整体效益最优。

结束语 MCS 作为一种新兴感知模式,通过整合和利用广泛分布的感知设备,为多样化的应用场景提供实时数据资源。针对 MCS 中任务分配的均衡性问题,本文提出一种创新的以用户为中心的动态负载均衡策略。首先,构建了一个以用户为中心的长时域动态任务分配模型。然后,考虑到模型的动态性和持续性特点,提出基于改进的 Lyapunov 优化方法进行求解,实现系统整体效益和用户负载均衡性的双重优化。最后,通过仿真实验,验证了所提算法的有效性。结果证明,在确保队列稳定性和系统整体效益最优的前提下,所提算法实现了较好的负载均衡性。在未来的工作中,将进一步考

虑任务的时间敏感性,着重优化任务队列节点的优先级分配机制,满足用户和任务对实时性的需求。

参 考 文 献

- [1] GANTI R K, YE F, LEI H. Mobile crowdsensing: current state and future challenges [J]. IEEE Communications Magazine, 2011, 49(11): 32-39.
- [2] GONG W, ZHANG B, LI C. Task Assignment in Mobile Crowdsensing: Present and Future Directions [J]. IEEE Network, 2018, 32(4): 100-107.
- [3] LIU S, WAN Z, YUAN Y, et al. An Efficient Certificateless Blind Signature Scheme With Conditional Revocation for Mobile Crowd Sensing Within Smart City [J]. IEEE Internet of Things Journal, 2024, 11(9): 15985-15997.
- [4] ALHAZEMI F. Sequential Clustering Phases for Environmental Noise Level Monitoring on a Mobile Crowd Sourcing/Sensing Platform [J]. Sensors, 2025, 25(5): 1601.
- [5] JIANG Z, ZHU H, ZHOU B, et al. CrowdPatrol: A Mobile Crowdsensing Framework for Traffic Violation Hotspot Patrolling [J]. IEEE Transactions on Mobile Computing, 2023, 22(3): 1401-1416.
- [6] LIU Y, YU Z, CUI H, et al. SafeCity: A Heterogeneous Mobile Crowd Sensing System for Urban Public Safety [J]. IEEE Internet of Things Journal, 2023, 10(20): 18330-18345.
- [7] MEITEI M G, MARCHANG N. Provisioning Load Balancing in Time-Sensitive Task Allocation for Mobile Crowdsensing [J]. Journal of Network and Systems Management, 2024, 32(1): 13.
- [8] BAJAJ G, SINGH P. Load-Balanced Task Allocation for Improved System Lifetime in Mobile Crowdsensing [C] // 2018 19th IEEE International Conference on Mobile Data Management (MDM). IEEE, 2018: 227-232.
- [9] WU F, YANG S, TANG S, et al. Fine-Grained User Profiling for Personalized Task Matching in Mobile Crowdsensing [J]. IEEE Transactions on Mobile Computing, 2021, 20(10): 2961-2976.
- [10] GAO H, ZHAO H. A Personalized Task Allocation Strategy in Mobile Crowdsensing for Minimizing Total Cost [J]. Sensors, 2022, 22(7): 2751.
- [11] SIMON B, ORTIZ A, SAAD W, et al. Decentralized Online Learning in Task Assignment Games for Mobile Crowdsensing [J]. IEEE Transactions on Communications, 2024, 72(8): 4945-4960.
- [12] ZHANG J, ZHANG X. Multi-Task Allocation in Mobile Crowd Sensing With Mobility Prediction [J]. IEEE Transactions on Mobile Computing, 2023, 22(2): 1081-1094.
- [13] SUN G, WANG Y, DING X, et al. Cost-Fair Task Allocation in Mobile Crowd Sensing With Probabilistic Users [J]. IEEE Transactions on Mobile Computing, 2021, 20(2): 403-415.
- [14] LI Y, LI H, MEI B, et al. Fairness-Guaranteed Task Assignment for Crowdsourced Mobility Services [J]. IEEE Transactions on Mobile Computing, 2024, 23(5): 5385-5400.
- [15] SONG X, WANG E, LIU W, et al. Fairness task assignment

- strategy with distance constraint in Mobile CrowdSensing[J]. CCF Transactions on Pervasive Computing and Interaction, 2023, 5(2):184-205.
- [16] AN X, GUO H, WANG X, et al. Load Balanced Mobile User Recruitment for Mobile Crowdsensing Systems[J]. IEEE Communications Letters, 2017, 21(11):2420-2423.
- [17] WANG T, ZHANG Y, SHEN H, et al. Task Partitioning and Scheduling Based on Stochastic Policy Gradient in Mobile Crowdsensing[J]. IEEE Transactions on Computational Social Systems, 2024, 11(5):6580-6591.
- [18] NEELY M. Stochastic Network Optimization with Application to Communication and Queueing Systems[M]. San Rafael: Morgan & Claypool Publishers, 2010.
- [19] LUAN D, WANG E, LIU W, et al. Stability-aware data offloading optimization in edge-based mobile crowdsensing[J]. Frontiers of Computer Science, 2025, 19(11):1-15.
- [20] DUAN J, LU J, JIANG W, et al. Incentivizing fairness-aware task allocation in mobile crowdsensing with sweep coverage and stability control[J]. Applied Soft Computing, 2020, 97(9):1-11.
- [21] WANG X, JIA R, TIAN X, et al. Location-Aware Crowdsensing: Dynamic Task Assignment and Truth Inference[J]. IEEE Transactions on Mobile Computing, 2020, 19(2):362-375.
- [22] GUO M, WANG X. Dynamic Scheduling for Quality of Information Maximization in Location-aware Opportunistic Mobile Crowdsensing[C]//2023 IEEE 34th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). IEEE, 2023:1-6.
- [23] CHANG S, DENG S, WU Y, et al. Online Energy Balancing Strategy Based on Lyapunov Optimization in Mobile Crowdsensing[J]. IEEE Transactions on Industrial Informatics, 2023, 19(9):1-13.
- [24] ZHENG Y, ZHANG L, XIE X, et al. Mining Interesting Locations and Travel Sequences from GPS Trajectories[C]// Proceedings of the 18th International Conference on World Wide Web. ACM, 2009:791-800.



LI Fan, born in 2002, postgraduate. Her main research interests include mobile crowdsensing and optimization algorithm.



WU Yahui, born in 1983, Ph.D, associate professor. His main research interests include Internet of Things, network optimization and data mining.

(责任编辑:李亚辉)