

基于李雅普诺夫优化的移动群智感知在线任务分配策略

常沙, 吴亚辉, 邓苏, 马武彬, 周浩浩

引用本文

常沙, 吴亚辉, 邓苏, 马武彬, 周浩浩 [基于李雅普诺夫优化的移动群智感知在线任务分配策略](#) [J]. 计算机科学, 2023, 50(2): 50-56.

CHANG Sha, WU Yahui, DENG Su, MA Wubin, ZHOU Haohao. [Online Task Allocation Strategy Based on Lyapunov Optimization in Mobile Crowdsensing](#) [J]. Computer Science, 2023, 50(2): 50-56.

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)

[空地协同移动群智感知研究综述](#)

Review of Mobile Air-Ground Crowdsensing

计算机科学, 2022, 49(11): 242-249. <https://doi.org/10.11896/jsjcx.220400264>

[基于分层抽样优化的面向异构客户端的联邦学习](#)

Federated Learning Based on Stratified Sampling Optimization for Heterogeneous Clients

计算机科学, 2022, 49(9): 183-193. <https://doi.org/10.11896/jsjcx.220500263>

[边缘计算中面向数据流的实时任务调度算法](#)

Task Offloading Online Algorithm for Data Stream Edge Computing

计算机科学, 2022, 49(7): 263-270. <https://doi.org/10.11896/jsjcx.210300195>

[基于DBSCAN聚类的集群联邦学习方法](#)

Clustered Federated Learning Methods Based on DBSCAN Clustering

计算机科学, 2022, 49(6A): 232-237. <https://doi.org/10.11896/jsjcx.211100059>

[基于改进多目标进化算法的微服务用户请求分配策略](#)

Microservices User Requests Allocation Strategy Based on Improved Multi-objective Evolutionary Algorithms

计算机科学, 2021, 48(10): 343-350. <https://doi.org/10.11896/jsjcx.201100009>

基于李雅普诺夫优化的移动群智感知在线任务分配策略

常沙 吴亚辉 邓苏 马武彬 周浩浩

国防科技大学系统工程学院 长沙 410005

(changsha18@nudt.edu.cn)

摘要 移动群智感知技术基于众包思想,募集移动感知设备对周围环境进行感知,能够使得环境感知和信息收集更加灵活、方便、高效。任务分配方案的合理性直接影响到感知任务能否成功,因此制定合理的任务分配方案是移动群智感知相关研究中的热点和重点。目前,移动群智感知系统中的任务分配方法多是离线的,针对的是单一类型的任务,但是在实际中,在线的、多类型的任务分配更贴近实际。因此,文中针对多类型任务,将移动群智感知技术应用于军事末端感知中,结合移动群智感知技术在军事领域的应用特点,对移动群智感知中的任务分配方法进行了研究,提出了面向系统效益的在线任务分配策略。文中建立了长期的、动态的在线任务分配系统模型,并以系统效益为优化目标,基于李雅普诺夫优化理论对问题进行了求解,实现了任务准入策略和任务分配方案的长期在线动态控制。实验结果表明,所提出的在线任务分配算法是有效可行的,能够在线、合理地分配到达移动群智感知系统的任务,保证任务队列的稳定性,且可以通过调整参数值增加系统效益。

关键词: 移动群智感知;系统效益;李雅普诺夫优化;任务队列稳定性

中图分类号 TP393

Online Task Allocation Strategy Based on Lyapunov Optimization in Mobile Crowdsensing

CHANG Sha, WU Yahui, DENG Su, MA Wubin and ZHOU Haohao

College of Systems Engineering, National University of Defense Technology, Changsha 410005, China

Abstract Based on the idea of crowdsourcing, mobile crowdsensing (MCS) collects mobile sensing devices to sense the surrounding environment, which can make environment sensing and information collection more flexible, convenient and efficient. Whether the task allocation strategy is reasonable or not directly affects the success of the sensing task. Therefore, formulating a reasonable task allocation strategy is a hotspot and focus in the research of MCS. At present, most of the task allocation methods in MCS systems are offline and targeted at single type tasks. However, in practice, online multi-type task allocation is more common. Therefore, this paper studies the task allocation method in MCS for multiple types of tasks, and proposes an online task allocation strategy oriented to system benefits combined with the characteristics of MCS technology in the military field. In this paper, a long-term, dynamic online task allocation system model is established, and the problem is solved based on Lyapunov optimization theory with the system benefit as the optimization goal, so that the online dynamic control of task admission strategy and task allocation scheme is realized. Experiment shows that the online task allocation algorithm proposed in this paper is effective and feasible. It can reasonably allocate the tasks arriving at the MCS system online, ensure the stability of the task queue, and increase the system utility by adjusting the parameter value.

Keywords Mobile crowdsensing, System utility, Lyapunov optimization, Stability of task queue

1 引言

大数据在引领信息领域变革的同时,也在逐步改变着战争形态和作战方式。获取全面的战场态势、快速反应、准确决策都需要海量战场实时动态数据的支撑和保障^[1]。但是传统感知网络中存在末端感知节点短缺、数据采集手段弱、感知数据更新缓慢及软硬件设施缺乏自主性等问题,严重影响了军事感知数据的采集、传输和应用。

随着感知设备小型化,越来越多的感知器件,如相机、麦克风、加速度计、电子罗盘等,被嵌入到移动设备中,如智能手机、智能手表、无人驾驶车辆等。移动群智感知^[2]应运而生,它将众包思想和移动感知相结合,是一种新颖的物联网感知范式。通过招募和协调感知设备,对周围环境进行感知以满足其他应用需求,如在军事斗争中,借助移动群智感知收集的丰富感知数据能够有效开展情报获取与收集、作战对象侦查监视等工作^[3]。

到稿日期:2022-11-21 返修日期:2023-01-13

基金项目:国家自然科学基金(61871388)

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

通信作者:吴亚辉(wuyahui@nudt.edu.cn)

在移动群智感知中,任务分配方案的合理性直接影响到感知任务能否成功,而目前现有的任务分配方案多为面向单类型任务的、离线的,不适用于军事末端感知领域。因此,制定合理的任务分配方案是亟待解决的问题。

本文结合移动群智感知技术应用在军事末端感知中的特点,研究了面向系统效益的多类型任务在线分配问题,提出了基于李雅普诺夫优化的移动群智感知在线任务分配策略。该策略能够在保证移动群智感知系统稳定性的同时,使得系统效益最大化,促进末端感知和数据采集任务的完成,从而高效提供作战数据保障,增强战场态势感知能力。

2 移动群智感知及其任务分配

2.1 概述

移动群智感知由 Ganti 等^[3]于 2011 年首次提出,用于表示广泛的社区感知。移动群智感知提供了一种收集感知数据并提取有效信息的范式,该范式包含大量具有感知功能和计算能力的移动设备,这些移动设备中嵌入了各种感知设备,因此可以用于感知周围环境,如监测空气质量、噪音指数、交通拥堵状况等。获取感知数据后,移动设备通过蜂窝移动网络、WIFI 或蓝牙等方式,将数据上传至数据收集服务器,为各类应用提供数据支持。

2.2 军事应用特点

移动群智感知技术对于军事末端感知和数据保障具有深远的意义。军事末端感知中的“末端”指能够直接感知、获取战场数据的各类终端,通常分布在战场的最前端,可以视作战场感知的“触角”,如地面传感器、雷达、无人机等。军事末端感知以满足作战需求为目的,能够及时感知、获取、收集、发送各类战场数据,生成战场态势信息,从而支撑辅助作战指挥和决策。传统的军事末端感知手段有地面监测、雷达成像、无人机拍摄及卫星传感等。

移动群智感知应用于军事末端感知,能够有效扩充末端感知的方式和手段,为作战及时、精准、高效地提供数据保障,增强战场态势感知能力。美军以单兵夜视设备、热成像设备、单兵电台等作为感知节点,通过数据的感知、收集和应用,以全面采集环境数据、掌握整个战场环境^[5-6];再如,通过单兵电子生命监测设备,可以及时有效地定位和搜救战场伤病员,从而更好地做到应急救援和医疗资源调度,全面地提升医疗保障力。实际上,除了单兵作战人员外,作战车辆、无人机等均可以作为感知节点执行感知任务,实时获取战场信息,有效提升战场态势感知能力,从而获取信息优势^[7]。另外,当地居民的智能感知设备也可以作为感知节点,实时监测当地情况,如民情、舆情、气象、水文等。

2.3 任务分配

移动群智感知系统主要由感知平台和感知参与者组成,如图 1 所示。感知平台接收到外界应用程序发布的感知任务后,根据任务分配方案,选择合适的感知参与者执行任务,随后收集并整理参与者回传的感知数据,将其发送给外界应用程序,从而获取效益。上述工作流程可以大致概括为:任务分配、数据感知、数据处理和数据上传 4 个阶段^[8]。移动群智感

知的相关研究主要围绕上述 4 个阶段展开,其中任务分配是移动群智感知的关键环节^[9]。任务分配方案的制定通常需要考虑多种因素,既要考虑感知参与者的能量消耗、感知成本及隐私安全等问题,又要考虑数据质量、任务时限、支出约束及公平性等因素。

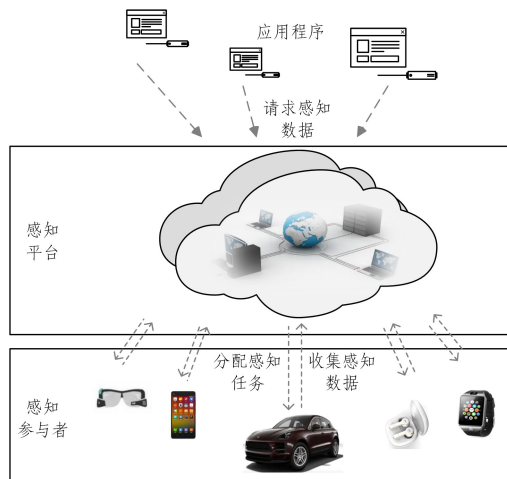


图 1 移动群智感知典型系统示意图

Fig. 1 Typical composition of MCS system

在移动群智感知系统的任务分配问题中,根据分配模式的不同,可以将其分为离线分配和在线分配。离线分配通常是对确定的在一定时间区间内的任务进行分配。但是,在线任务分配中,任务并非是确定在特定时间区间内的,而是根据实际情况到达的,系统需要随时决定是否执行及如何执行任务。

移动群智感知系统中的感知任务可以分为单类型任务和多类型任务。单类型任务指外部应用程序仅向移动群智感知系统请求单一类型的数据,因此系统中的感知任务类型是单一的。例如,对于室内定位应用程序,系统只需要提供位置数据,因此仅涉及到单类型任务分配问题。而多类型任务指外部应用程序较多,向移动群智感知系统请求的数据也较复杂,包含多种类型,如文本、图片、音频、视频等,此时系统便需要对多类型任务进行分配和执行。

任务分配方案的合理性直接影响到感知任务能否成功,因此制定合理的任务分配方案是移动群智感知相关研究中的热点和重点。针对 workflow 任务分配问题,Hu 等^[10]引入了 Q-learning 方法,提出了一种针对多目标的强化贪婪迭代方法,该方法适用于具有逻辑顺序关系的任务分配问题。但是,这种任务分配方法只有在请求者和其他用户相遇时才能运行。针对用于室内定位的感知任务,Ray 等^[11]提出了一种基于马尔可夫决策过程的任务分配策略。该策略通过参与者能量、计算负载和充电概率判断参与者的当前状态,进而决定任务分配情况。Xing 等^[12]针对空间任务的分配问题,以最小化感知成本为优化目标,设计了一种空间任务的分配机制。Liu^[13]考虑了用户意愿及用户间关系,结合任务分解方法及列表排序方法,提出了一种基于混合用户模型与排序学习算法相结合的协同排序任务推荐方法,从而实现了任务的合理分配。Liu 等^[14]则是开展问卷调查,研究了参与者能量对其参与意愿的影响,得到了设备能量、分配任务数量及拒绝概率

之间的关系。因此,根据参与者能量为其分配适当数量的感知任务,则该任务更有可能被执行,进而保证感知任务的完成。Jiang 等^[15]结合地铁交通的优势特点,对感知任务进行了分发,并对用户的激励成本和用户节点数量进行了优化,从而降低了任务成本。Guo^[16]提出了一种任务分配方法,以降低参与者中执行任务最大能耗负载的优化目标,并对该问题进行数学建模,在线性规划松弛的基础上利用启发式算法得到该问题的可行解,从而实现参与者负载均衡,使得每一个参与者都能有较好的任务体验,提高其执行任务的积极性。为了有效减少任务的完成时间,Peng 等^[17]分别提出了平均完成时间敏感的在线任务分配算法和最大完成时间敏感的在线任务分配算法。针对多任务分配问题,Han 等^[18]提出了一种面向用户区域的分布式多任务分配方法,该方法包括感知任务及用户区域分簇、任务路径构建、动态定价及任务分配等步骤。但该方法是一种批量任务分配,实际属于离线任务分配。Gong 等^[19]提出了基于质量/进度的任务分配算法、基于任务密度的任务分配算法、基于移动距离平衡的任务分配算法和仿生启发式-移动距离平衡算法,有效提高了任务分配质量;但是其没有考虑参与者的执行任务能力,可能会造成任务队列拥塞,无法保证队列的稳定性。

本文主要研究应用于军事末端感知的移动群智感知任务分配,其具有如下特点。1)加入感知系统的参与者并非以盈利为目的,而是为了满足作战需求,共同完成作战任务。参与者之间通常是协作关系,而非竞争关系。因此,系统的主要目的是提高任务完成率,增加系统效益。2)与其他群智感知系统中自由移动的感知参与者不同,军事应用中的感知参与者通常有计划地分布在特定区域,更有利于感知任务的执行。3)为了有效保障作战数据、满足作战需求,移动群智感知系统需要持续地执行感知任务、感知战场环境,因此应选择在线任务分配方式,而非离线任务分配方式。另外,感知数据通常包含多种类型,因此感知任务同样包含多种类型。

目前,移动群智感知系统的任务分配方法多是离线的,主要针对单一类型的任务,不适用于军事应用。因此,本文结合移动群智感知技术应用在军事末端感知中的特点,研究了面向系统效益的多类型任务在线分配问题。本文的主要贡献有:

(1)将移动群智感知技术应用用于军事末端感知中,有效扩充和丰富了军事末端感知的方式和手段。

(2)结合移动群智感知技术应用在军事末端感知中的特点,建立了多类型在线任务分配模型,并提出了目标函数。

(3)由于系统模型的动态性、不确定性、长期性和变量间的非线性关系,无法通过常规的最优化理论对优化目标进行求解和实现,因此本文采用李雅普诺夫优化理论,提出了基于李雅普诺夫优化的在线任务分配算法,从而实现了优化目标。

(4)实验结果表明,基于李雅普诺夫优化的在线任务分配算法是有效可行的,能够保证任务队列的稳定性,且可以通过调整 V 值使得系统效益最优。

3 移动群智感知系统在线任务分配模型

3.1 符号定义

本文使用的符号定义如表 1 所列。

表 1 符号定义

Table 1 Symbol definition

M	感知任务类型数量
j	不同的感知任务类型 $j \in \{1, \dots, M\}$
t	时隙, $t \in \{0, 1, 2, \dots\}$
$O_j(t)$	在时隙 t 到达感知平台的类型 j 的感知任务数量
O_j^{\max}	在时隙 t 到达感知平台的类型 j 的感知任务最大数量
λ_j	$O_j(t)$ 的期望值
$o_j(t)$	在时隙 t 经过平台选择决策后进入感知平台的类型 j 的感知任务数量
N	感知参与者数量
i	不同的感知参与者, $i \in \{1, \dots, N\}$
$x(t)$	在时隙 t 的任务分配情况
$x_{ij}(t)$	在时隙 t 是否将任务 j 分配给参与者 i
$r_j(t)$	任务 j 在时隙 t 能够被执行的数量
$Q(t)$	在时隙 t 平台内不同类型的感知任务队列积压向量
$Q_j(t)$	在时隙 t 平台内类型 j 的感知任务队列积压向量
$U(t)$	时隙 t 感知平台的效益
\bar{U}	$U(t)$ 的期望值
β	感知平台执行单位数量任务所能获得的效益,为正常数
V	非负常数

3.2 建立模型

在实际情况中,不同应用程序请求的感知数据不尽相同,因此本文研究的 MCS 系统同时存在多种类型的感知任务。假设有 M 类感知任务,令 j 表示不同的感知任务类型, $j \in \{1, \dots, M\}$ 。将时间划分为离散的等长的时隙 $t, t \in \{0, 1, 2, \dots\}$,每个时隙内到达平台的感知任务类型及数量均不同。 $O_j(t)$ 表示时隙 t 到达感知平台的任务 j 的数量,在每个时隙都是独立同分布的随机变量, $0 \leq O_j(t) \leq O_j^{\max}$ 。并非所有到达的感知任务都能进入感知平台被执行,平台根据前一时隙任务执行情况决定能够进入系统并被执行的感知任务,即选择决策。 $o_j(t)$ 表示时隙 t 进入感知平台的任务 j 的数量, $0 \leq o_j(t) \leq O_j(t)$ 。

在每个时隙,平台需要将不同类型的任务分配给感知参与者,即分配决策。 $x_{ij}(t)$ 表示在时隙 t 是否将任务 j 分配给参与者 i ,即参与者 i 是否执行任务 j ,当 $x_{ij}(t) = 1$ 时,参与者 i 执行任务 j ;当 $x_{ij}(t) = 0$ 时,参与者 i 不执行任务 j 。每个时隙内,同一参与者能够同时执行多种类型的单位数量的任务。任务分配后,任务 j 在时隙 t 能够被执行的数量表示为 $r_j(t)$:

$$r_j(t) = \sum_{i \in N} x_{ij}(t) \quad (1)$$

其中, $0 \leq r_j(t) \leq N$ 。

令 $Q(t) = (Q_1(t), Q_1(t), \dots, Q_M(t))$ 表示在时隙 t 平台内不同类型的感知任务队列积压向量,其动态变化情况服从式(2):

$$Q_j(t+1) = \max[Q_j(t) - r_j(t), 0] + o_j(t) \quad (2)$$

其中, $Q_j(0) = 0, j \in \{1, \dots, M\}, Q_j(t) \geq 0$ 。由文献[20]可知,若 $Q_j(t)$ 满足:

$$\lim_{t \rightarrow +\infty} \frac{E\{Q_j(t)\}}{t} = 0 \quad (3)$$

则 $Q_j(t)$ 是稳定的,即所有进入感知平台的感知任务均会被执行;当 $\{Q_j(t)\}, j \in \{1, \dots, M\}$ 均满足式(3)时,称 MCS 系统是稳定的。

3.3 系统效益

令 $U(t)$ 表示时隙 t 感知平台的效益,其大小取决于进入平台的感知任务数量。

$$U(t) = \beta \sum_{j=1}^M o_j(t) \quad (4)$$

其中, β 表示感知平台执行单位数量任务所能获得的效益,为正常数。

3.4 目标函数

本文要解决的问题是在满足感知任务队列稳定性的条件下,通过选择控制和任务分配,使得系统效益最大化。由于系统模型的动态性、不确定性和非线性,本文将其转化为时间平均约束下的系统效益的优化问题。该问题的目标函数如下:

$$\max \bar{U} = \max \limsup_{t \rightarrow +\infty} \frac{1}{t} \sum_{\tau=0}^{t-1} E\{U(\tau)\} \quad (5)$$

$$\text{s. t. } U(t) = \beta \sum_{j=1}^M o_j(t) \quad (6)$$

$$Q_j(t+1) = \max\{Q_j(t) - r_j(t), 0\} + o_j(t) \quad (7)$$

$$\lim_{t \rightarrow +\infty} \frac{E\{Q_j(t)\}}{t} = 0 \quad (8)$$

4 在线任务分配策略

为了解决上述优化问题(5)~问题(8),本文将该问题与排队论结合,采用李亚普诺夫优化理论,大大降低了问题求解的复杂度。李雅普诺夫优化理论^[20]是一种随机网络优化理论,经过 Neely 教授及其团队的研究和优化,目前该理论已较为成熟,被应用于多个领域。与其他静态优化算法不同的是,基于李雅普诺夫优化理论提出的算法是一种在线、动态、自适应的算法。当系统状态发生变化时,无需人为调整,该算法具有一定的自学习能力,能够保持渐进最优性。另外,基于李亚普诺夫优化理论的算法实现较简便,所需先验知识较少,且具有一定的解耦能力,能够大大降低算法设计的难度。

定义时隙 t 李雅普诺夫优化函数为:

$$L(t) = L(Q(t)) \triangleq \frac{1}{2} \sum_{j=1}^M Q_j^2(t) \quad (9)$$

定义李雅普诺夫漂移函数为:

$$\Delta(Q(t)) \triangleq E\{L(t+1) - L(t) | Q(t)\} \quad (10)$$

将效用函数作为惩罚函数加入上述漂移函数中,得到 drift-plus-penalty 函数:

$$\Delta_v(Q(t)) \triangleq E\{L(t+1) - L(t) | (Q(t))\} - VE\{U(t) | (Q(t))\} \quad (11)$$

其中, V 是一个非负常数。通过调节 V 值大小可以控制稳定性与效用函数间的比例关系。

定理 1 在每个时隙 t , 目标函数(5)~目标函数(8)的任意一个可行解,均满足以下不等式:

$$\Delta_v(Q(t)) \leq B + \sum_{j=1}^M Q_j(t)(o_j(t) - r_j(t)) - V\beta \sum_{j=1}^M o_j(t) \quad (12)$$

其中, $B = \frac{1}{2} \sum_{j=1}^M (N^2 + (O_j^{\max})^2)$ 。

证明:由 $0 \leq O_j(t) \leq O_j^{\max}$, $0 \leq o_j(t) \leq O_j(t)$ 可知 $0 \leq o_j(t) \leq O_j^{\max}$ 。另外:

$$(\max\{Q_j(t) - r_j(t), 0\})^2 \leq (Q_j(t) - r_j(t))^2 \quad (13)$$

对式(2)两边平方,根据上述不等式可得:

$$\begin{aligned} Q_j^2(t+1) &\leq (Q_j(t) - r_j(t))^2 + 2(Q_j(t) - r_j(t))o_j(t) + o_j^2(t) \\ &\leq (Q_j(t) - r_j(t))^2 + 2Q_j(t)o_j(t) + o_j^2(t) \end{aligned} \quad (14)$$

因此:

$$\frac{Q_j^2(t+1) - Q_j^2(t)}{2} \leq \frac{N^2 + (O_j^{\max})^2}{2} + Q_j(t)(o_j(t) - r_j(t)) \quad (15)$$

其中, $\frac{N^2 + (O_j^{\max})^2}{2}$ 是正常数。

$$-VE\{U(t) | (Q(t))\} = -V\beta \sum_{j=1}^M E\{o_j(t) | Q(t)\} \quad (16)$$

对式(13)取期望,并对 $j \in \{1, \dots, M\}$ 求和,再加上式(14)

的右侧,得到式(17):

$$\Delta_v(Q(t)) \leq B + \sum_{j=1}^M Q_j(t)(o_j(t) - r_j(t)) - V\beta \sum_{j=1}^M o_j(t) \quad (17)$$

定理 1 得证。

由定理 1 可以得到 drift-plus-penalty 函数的一个上界,为了实现队列稳定、效用最大化,需要使该上界在每个时隙都最小,对式(12)右边变形可得:

$$\Delta_v(t) \leq B + \sum_{j=1}^M o_j(t)(Q_j(t) - V\beta) - \sum_{j=1}^M Q_j(t)r_j(t) \quad (18)$$

接下来,对任务队列 $Q(t)$ 的稳定性进行证明。

定理 2 对于目标函数(5)~目标函数(8)的可行解,队列 $Q(t)$ 是稳定的。

证明:由文献[20]中 Theorem 4.5 及 Appendix 4. A 可知,如果目标函数(5)~目标函数(8)有可行解,那么对于任意 $\delta > 0$,都存在一个动态负载均衡策略能够满足如下条件。

对于任意 t , 有:

$$E\{U(t)\} \geq U^{\text{opt}} - \delta \quad (19)$$

$$E\{o_j(\tau)\} \leq E\{r_j(t)\} + \delta \quad (20)$$

其中, U^{opt} 表示所有可行解中系统效益的上确界。

由式(11)可得:

$$\begin{aligned} \Delta_v(Q(t)) &= E\{L(t+1) - L(t) | Q(t)\} - VE\{U(t) | Q(t)\} \\ &\leq \frac{N^2 + (O^{\max})^2}{2} + \sum_{j=1}^M Q_j(t)E\{o_j(t) - r_j(t) | Q(t)\} - VE\{U(t) | Q(t)\} \end{aligned} \quad (21)$$

当 $\delta = 0$ 时,由式(19)~式(21)可得:

$$\Delta_v(Q(t)) \leq B - VU^{\text{opt}} \quad (22)$$

其中, B 是正常数,且满足:

$$B \geq \frac{N^2 + (O^{\max})^2}{2} \quad (23)$$

由文献[20]中的 Theorem 4.2 可得,队列 $Q(t)$ 是稳定的。

定理 2 得证。

基于李雅普诺夫优化的移动群智感知在线任务分配策略如算法 1 所示。

算法 1 基于李雅普诺夫优化的移动群智感知在线任务分配策略

1. Set $Q_j(0) = 0$, $j \in \{1, \dots, M\}$
2. for each time slot t do
3. for $j \in \{1, \dots, M\}$ do
4. The platform determines $o_j(t)$ that minimize $\sum_{j=1}^M o_j(t)(Q_j(t) - V\beta)$
5. end for
6. The platform determines $x(t) = \{x_{ij}(t)\}$ that maximize $\sum_{j=1}^M Q_j(t)r_j(t)$
7. for $j \in \{1, \dots, M\}$ do
8. The platform updates $Q_j(t)$ according to equation (2)
9. end for
10. end for

其中, $\sum_{j=1}^M o_j(t)(Q_j(t) - V\beta)$ 随 $o_j(t)$ 线性变化,因此其最优解为:

(1) 当 $Q_j(t) - V\beta < 0$ 时, $o_j(t) = O_j(t)$;

(2) 否则, $o_j(t) = 0$ 。

为了使上界最小,应使 $\sum_{j=1}^M Q_j(t)r_j(t)$ 最大化:

(1) 当 $Q_j(t) + o_j(t) \geq N$ 时, $x_{ij}(t) = 1$, $i \in \{1, \dots, N\}$, $j \in \{1, \dots, M\}$,即为了实现效益最大化,所有参与者均执行任务。

(2) 当 $Q_j(t) + o_j(t) < N$ 时,选择 $(Q_j(t) + o_j(t))$ 个参与者执行队列中的任务。

5 仿真实验

下面对基于李雅普诺夫优化的在线任务分配算法性能进行实验评估。

本文设置了5种不同类型的感知任务,在每一时隙不同类型任务到达感知平台的数量不同,分别服从不同参数 λ 的泊松分布,不同实验中的具体参数设置不同。实验中假设有5个参与者执行感知任务。每个时隙内,同一参与者能够执行多种类型的单位数量的感知任务。本文中,设置 $\beta=1$ 。

实验1 算法对比实验。为了验证基于李雅普诺夫的在线任务分配算法的性能,本文将所提算法、QPA算法^[19]及离线任务分配算法的系统效益进行对比。设置不同类型的任务到达数量分别服从泊松分布,参数设置如表2所列。 $V=27000$,具体原因见实验2中的分析。实验共运行1000个时隙,即 $t \in \{0, 1, \dots, 999\}$ 。实验结果如图2所示。

表2 实验参数设置

Table 2 Experimental parameter setting

λ_1	λ_2	λ_3	λ_4	λ_5	β	M	N
10	15	15	25	15	1	5	5

图2给出了不同任务分配算法的系统效益随着时间的变化情况。由图2可以看出,基于李雅普诺夫优化的在线任务分配算法和QPA算法的系统效益明显高于离线任务分配算法。其原因在于:在离线任务分配算法中,系统效益主要取决于当前时刻参与者的任务执行能力。对于当前时间段无法执行的任务,其处理策略是直接丢弃。但是,在本文提出的基于李雅普诺夫优化的在线任务分配算法中,各类任务经过系统的选择决策后进入任务队列,随后根据分配策略被合理地分配给参与者执行,未被执行的任务等待后续分配和执行,从而

确保了任务的执行率,进而提升了系统效益。QPA算法得到的系统收益与基于李亚普儒夫优化的在线任务分配算法持平,同样高于离线分配算法。




图2 不同任务分配算法的系统效益对比图

Fig. 2 Comparison of system utility of different task allocation algorithms

需要指出的是,QPA算法未考虑参与者执行任务的能力,无法保证任务队列的稳定性。当到达任务较多、执行任务能力较低时,任务队列将会剧烈增长,导致队列拥塞明显,无法实现任务队列的稳定性。在基于李雅普诺夫优化的在线任务分配算法中,约束 $\lim_{t \rightarrow +\infty} \frac{E\{Q_i(t)\}}{t} = 0$ 能够保证任务队列的稳定性,任务队列不会无限增长而超出参与者的能力范围,即所有进入任务队列的感知任务都能够被执行。因此,基于李雅普诺夫优化的在线任务分配算法在满足任务队列稳定性的前提下,保证了系统效益,优于其他两种任务分配算法。

实验2 为了观察系统效益 $U(t)$ 随 V 的变化情况,分别设置 $V=3000, V=6000, V=9000, V=12000, V=15000, V=18000, V=21000, V=24000, V=27000$ 。设置不同类型的任务到达数量分别服从泊松分布,参数如表2所列。实验共运行1000个时隙,即 $t \in \{0, 1, \dots, 999\}$ 。实验结果如图3所示。

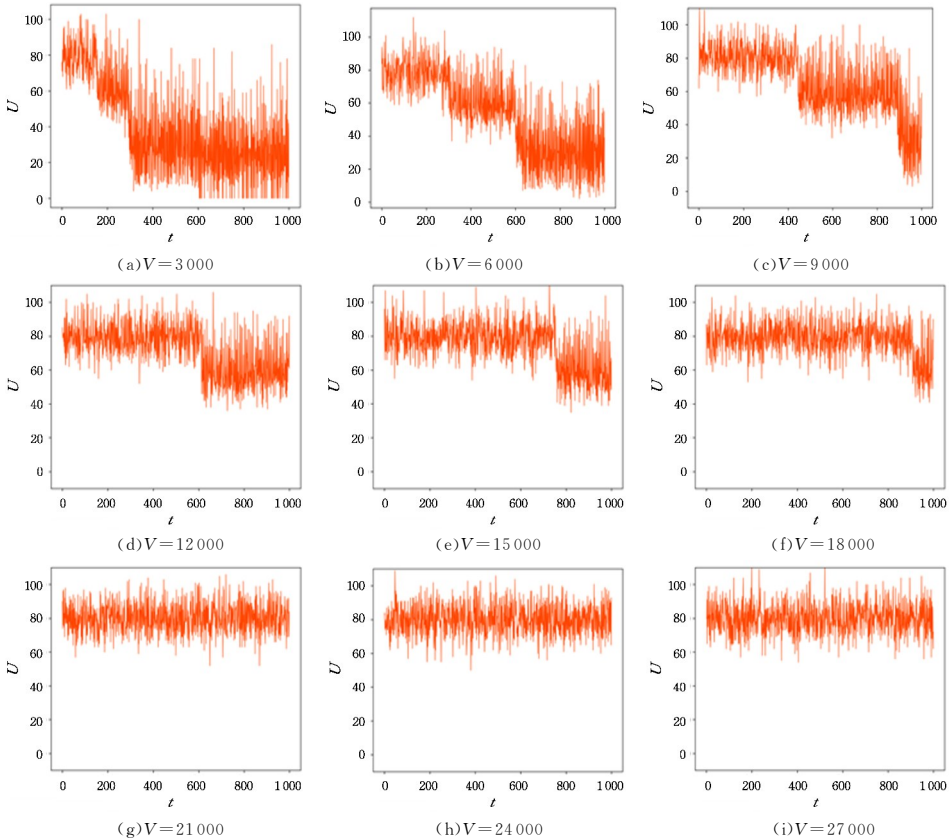


图3 不同 V 值下系统效益 $U(t)$ 的变化情况

Fig. 3 Variation curves of system utility $U(t)$ with different V

由图3可以看出, V 值不同,系统效益 $U(t)$ 的变化情况也不尽相同。随着 V 值逐渐增大, $U(t)$ 的均值也在逐渐增大,稳定在80附近的时间越长。上述现象是由式(18)决定的。 $Q_j(t) < V\beta$ 时, $o_j(t) = O_j(t)$, V 值越大, $Q_j(t)$ 的收敛速度越慢,故 $o_j(t) = O_j(t)$ 的时隙越多;且 $U(t) = \beta \sum_{j=1}^M o_j(t)$,因此 V 越大, $U(t)$ 维持在80附近的时间越长。因此,通过调节 V 值大小可以控制任务队列稳定性与系统效益之间的比例关系,即当 V 越大时,系统效益越大,但任务队列 $Q(t)$ 的收敛速度越慢,队列稳定所需时间越长;反之,系统效益越小,收敛速度越快,队列稳定所需时间越短。但是需要注意的是,无论 V 值如何增加, $U(t)$ 都不会一直维持在80附近,由于 $Q_j(t)$ 具有稳定性, $U(t)$ 将会随着时间的增长而降低。

实验3 为了进一步研究 V 值对系统效益的影响程度,本文对系统效益指标进行了细化,并进行了仿真实验。将系统效益指标分为总效益 U_{sum} 指标和平均效益 U_{avg} 指标。


总效益指所有时隙内系统的总效益,即:

$$U_{sum} = \sum_{t=0}^{T-1} U(t)$$


平均效益指总效益在所有时隙上的平均值,即:

$$U_{avg} = \frac{1}{T} U_{sum}$$

分别设置 $V = 5000, V = 10000, V = 15000, V = 20000, V = 25000, V = 30000$,观察系统效益的变化情况。实验共运行1000个时隙,即 $t \in \{0, 1, \dots, 999\}$ 。实验结果如图4所示。



(a) 总效益 U_{sum} 随 V 值的变化情况



(b) 平均效益 U_{avg} 随 V 值的变化情况

图4 系统总效益、系统平均效益随 V 值的变化情况

Fig. 4 Variation curves of total system utility and average system utility with different V

由图4可以看出,随着 V 值增大,总效益 U_{sum} 和平均效益 U_{avg} 均逐渐增大,随后均趋于稳定,最终在 $U_{avg} = 80$ 时达到最大值。从图中可以看出,当 $V = 20000$ 时, U_{avg} 已经接近最大值,趋于平稳,之后 V 值增加将不会提高平均效益。上述现象由式(18)决定,与实验2相似,此处不再赘述。 V 越大, U_{avg} 也越大。本文假设参与者在单个时隙内仅可以执行不同类型的单位数量的任务,因此平均效益 U_{avg} 最大不超过 $\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 + \lambda_5 = 80$ 。另外,从式(11)中

可以看出, V 值大小决定了系统效益的重要程度。 V 值越大,系统效益在李雅普诺夫漂移函数中的占比越大,因此平均效益值 U_{avg} 越大,但由于参与者执行任务能力有限, U_{avg} 趋于最大值后便不再增加。因此,系统可以通过增大 V 值来适当提高系统效益。

实验4 为了进一步观察任务队列 $Q(t)$ 的变化情况及其稳定性,本文提出了平均队列长度指标 $Q_{avg}(t)$, $Q_{avg}(t) = \frac{1}{M} \sum_{j=1}^M Q_j(t)$,即不同类型的任务队列长度平均值。分别设置 $V = 3000, V = 6000, V = 9000, V = 12000, V = 15000, V = 18000, V = 21000, V = 24000, V = 27000$,观察任务队列在不同 V 值下随时间的变化情况。实验共运行6000个时隙,即 $t \in \{0, 1, \dots, 5999\}$ 。实验结果如图5所示。




图5 V 值不同时,平均队列长度 $Q_{avg}(t)$ 的变化情况
Fig. 5 Variation curves of average queue length $Q_{avg}(t)$

由图5可以看出,不同 V 值下,任务队列 $Q_{avg}(t)$ 最终都趋于稳定,验证了系统的稳定性和在线任务分配策略的有效性和可行性。由图5可知, V 值不同,任务队列趋于稳定的速度不同; V 值越大,队列稳定所需时间越长。这是由式(18)决定的。当 $Q_j(t) < V\beta$ 时, $o_j(t) = O_j(t)$, $Q_{avg}(t)$ 不断增大;任务队列 $Q_j(t)$ 增大至 $V\beta$ 时, $o_j(t) = 0$, $Q_{avg}(t)$ 趋于平稳,并最终在 V 值附近收敛。因此, V 值越大, $Q_{avg}(t)$ 的收敛速度越慢,即 $Q_{avg}(t)$ 收敛所需的时间越长,收敛值越大。 $Q(t)$ 的稳定性得到了验证。需要指出的是,从图中可以看出任务队列的收敛值较大,这是由本文设置的参与者数量较少但到达的任务较多造成的。系统可以通过招募更多的参与者增大任务执行能力,从而减少队列积压。以上实验结论与实验2中所得结论一致。

通过以上实验可以看出,本文提出的移动群智感知中基于李雅普诺夫优化的在线任务分配算法是有效可行的,能够保证任务队列的稳定性,且可以通过调整 V 值使得系统效益最优。

结束语 移动群智感知技术通过募集和协调大量感知设备,对周围环境进行感知,为各类应用提供数据支持,近年来受到了广泛关注。本文将移动群智感知技术应用于军事末端感知中,结合其应用特点,提出了一种面向系统效益的多类型任务在线分配策略。首先,建立了系统模型,将系统效益作为目标函数,基于李雅普诺夫优化算法对问题进行了求解,实现了任务准入方案和任务分配策略的长期在线动态控制,并通过实验验证了该策略的性能和系统稳定性。

为了保证系统稳定性,本文设计的在线任务分配策略采取首先选择任务进入平台的任务队列,分配给参与者执行的方法。感知任务在被执行前将被筛选和丢弃。因此,如何制定合理的标准,对任务进行选择,将是下一步研究的重点。

参 考 文 献

- [1] CUI L F, GUO Y H, SHAO P Z, et al. Enhancing situational awareness on the battlefield using spatio-temporal big data [J]. *National Defense Science & Technology*, 2021, 42(2): 127-132.
- [2] CAPPONI A, FIANDRINO C, KANTARCI B, et al. A Survey on Mobile Crowdsensing Systems; Challenges, Solutions and Opportunities [J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(3): 2419-2465.
- [3] GANTI R K, FAN Y, LEI H. Mobile crowdsensing: current state and future challenges [J]. *IEEE Communications Magazine*, 2011, 49(11): 32-39.
- [4] CHEN X, WANG L, LIU W, et al. On Present Situation of Mobile Edge Information Service Ability of the US Army [J]. *Electronics Optics & Control*, 2021, 28(7): 62-67.
- [5] ZENG M Q, SHI K, CHEN J, et al. Research on Big Data Construction and Security of the U. S. Army [J]. *Communication Technology*, 2022, 55(7): 911-918.
- [6] DUAN Y X, LIU C Y, WEI W F. Review of Key Technologies for Battlefield Situational Awareness [J]. *Fire Control & Command Control*, 2021, 46(11): 1-19.
- [7] LIAO J H, WU Z W, LIU Y M, et al. Design and implementation of mobile crowdsensing platform [J]. *Journal of Zhejiang University*, 2020, 54(10): 1915-1922.
- [8] CHEN Y Y, LV P, GUO D K, et al. A Survey on Task and Participant Matching in Mobile Crowd Sensing [J]. *Journal of Computer Science and Technology*, 2018, 33(4): 768-791.
- [9] HU H, ZHANG Q, HU H Y, et al. Q-learning based sensing task assignment algorithm for mobile crowd sensing system [J]. *Computer Integrated Manufacturing Systems*, 2018, 24: 1774-1783.
- [10] RAY A, CHOWDHURY C, MALLICK S, et al. Designing Energy Efficient Strategies Using Markov Decision Process for Crowd-Sensing Applications [J]. *Mobile Networks and Applications*, 2020, 25(11): 932-942.
- [11] XING Q, SUN X M, YUAN C M. Assignment mechanism for spatial tasks in mobile crowd sensing [J]. *Application Research of Computers*, 2020, 37(3): 868-871.
- [12] LIU J X. Research on Task Assignment and Evaluation Method of Mobile Crowd Sensing for Quality Assurance [D]. Harbin: Harbin University of Science and Technology, 2021.
- [13] LIU C H, ZHANG B, SU X, et al. Energy-Aware Participant Selection for Smartphone-Enabled Mobile Crowd Sensing [J]. *IEEE System Journal*, 2017, 11(3): 1435-1446.
- [14] JIANG W J, LV S J, LIU Y H, et al. Task Distribution Method of Participatory Sensing Based on Urban Rail Transit [J]. *Journal of Electronics & Information Technology*, 2021, 43(10): 3035-3042.
- [15] GUO H. Research on incentive mechanism and task assignment in mobile crowdsensing [D]. Hefei: Hefei University of Technology, 2018.
- [16] PENG S, GONG W, ZHANG B X, et al. AP-Assisted Online Task Assignment for Mobile Crowdsensing [C] // 2019 IEEE Global Communications Conference, 2019.
- [17] HAN J Y, ZHANG Z Y, KONG D S. Distributed Multi-task Allocation Method for User Area in Mobile Crowd Sensing [J]. *Journal of Computer Applications*, 2020, 40(2): 358-362.
- [18] GONG W, ZHANG B X, LI C. Location-Based Online Task Assignment and Path Planning for Mobile Crowdsensing [J]. *IEEE Transactions on Vehicular Technology*, 2018, 68(2): 1772-1783.
- [19] NEELY J. Stochastic Network Optimization with Application to Communication and Queueing Systems [M]. San Rafael, CA, USA: Morgan and Claypool Publishers, 2010.



CHANG Sha, born in 1991, Ph.D. Her main research interests include mobile crowdsensing, Internet of Things, and mobile networks.



WU Yahui, born in 1983, Ph.D, associate professor. His main research interests include mobile networks, wireless communications, and performance evaluation.

(责任编辑: 喻黎)