

群组协作的移动群智感知任务分配方法

吴大鹏 管 芃 张普宁* 杨志刚 王汝言

(重庆邮电大学通信与信息工程学院 重庆 400065)

(先进网络与智能互联技术重庆市高校重点实验室 重庆 400065)

(泛在感知与互联重庆市重点实验室 重庆 400065)

摘要: 时空覆盖类感知任务对参与者的时间与空间约束使得传统单参与者模式难以适用。为此, 该文提出群组协作的移动群智感知任务分配方法, 以群组模式替代传统单参与者模式。设计层次化群组协作的任务分配框架, 提出偏好感知的社交群组生成方法, 引入社交关系生成社交群组, 提高任务完成率。提出效用优化的任务群组匹配方法, 采用网络流理论进行群组-任务匹配, 保证平台效用最大化。仿真结果表明所提方法在任务完成率与平台效用方面均有较大提升。

关键词: 移动群智感知; 任务分配; 群组协作; 平台效用

中图分类号: TN929.5; TP391

文献标识码: A

文章编号: 1009-5896(2023)12-4308-09

DOI: [10.11999/JEIT221046](https://doi.org/10.11999/JEIT221046)

Task Allocation Method of Mobile Crowdsensing Based on Group Collaboration

WU Dapeng GUAN Peng ZHANG Puning YANG Zhigang WANG Ruyan

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

(Advanced Network and Intelligent Connection Technology Key Laboratory of Chongqing Education Commission of China, Chongqing 400065, China)

(Chongqing Key Laboratory of Ubiquitous Sensing and Networking, Chongqing 400065, China)

Abstract: The temporal and spatial constraints of spatio-temporal coverage tasks make it difficult to utilize the traditional single-participant model. Therefore, a task allocation method based on group collaboration in mobile crowdsensing is proposed to replace the traditional single participant mode with group mode. A task allocation framework for hierarchical group collaboration and a preference-aware social group generation method is proposed. In addition, social groups are generated by introducing social relationships to improve the task completion rate. A task-group matching method for utility optimization is proposed, and the network flow theory is used to perform group-task matching to ensure the maximum utility of the platform. Simulation results show that the proposed method can improve the task completion rate and platform utility.

Key words: Mobile crowdsensing; Task assignment; Group collaboration; Platform utility

收稿日期: 2022-08-09; 改回日期: 2023-04-20; 网络出版: 2023-04-23

*通信作者: 张普宁 zhangpn@cqupt.edu.cn

基金项目: 国家自然科学基金(61901071, 61871062, 61771082, U20A20157), 重庆市自然科学基金(cstc2020jcyj-zdxmX0024), 重庆市高校创新研究群体(CXQT20017), 重庆高校创新团队建设计划(CXTDX201601020)

Foundation Items: The National Natural Science Foundation of China (61901071, 61871062, 61771082, U20A20157), The Science and Natural Science Foundation of Chongqing, China (cstc2020jcyj-zdxmX0024), The University Innovation Research Group of Chongqing (CXQT20017), The Program for Innovation Team Building at Institutions of Higher Education in Chongqing (CXTDX201601020)

1 引言

任务分配是移动群智感知面临的主要问题之一，主要解决在特定的任务要求约束下以感知任务为导向的感知参与者的选择问题，任务分配的结果将直接关乎感知任务的成败。传统的任务分配的研究主要针对单个参与者，在这些研究中单个感知任务由单个参与者完成。然而，在某些感知场景(例如智慧交通)中，参与者需要在特定区域感知足够的时间。上述场景中的任务属于时空覆盖任务的范围，需要来自足够多的感知区域的有足够时间的感知数据。通常，任务的覆盖范围相对较大，并且任务的持续时间很长。因此，单个参与者无法在整个时间段内覆盖整个任务区域。在解决这类协作任务时，往往需要多个参与者合作完成^[1]。因此，设计面向参与者群组的任务分配机制是执行时空覆盖感知任务的关键。然而，当前大多数的移动群智感知任务分配的研究都是假设感知平台拥有充足的感知参与者历史信息^[2-4]。对于新成立的感知平台，感知平台中存在新老参与者交替的情况，对于老参与者可以通过分析参与者的历史数据进行任务分配，对于新参与者感知平台由于没有参与者的历史信息，将会存在任务无法有效分发的“冷启动”问题。当前，已有部分文献研究了群组模式的群智感知^[1,5,6]，它们都忽视了多个感知任务并行处理的情况。因此，在生成感知群组之后，需要进一步设计合理的任务-群组匹配机制来保证感知任务的成功完成。

随着在线社交网站的蓬勃发展，每个用户的兴趣可能与其好友相似或受其好友影响。因此，用户间的社交关系提供了有关用户的额外信息，并且可以缓解“冷启动”问题^[7]。本文基于社交关系思想，设计群组协作的面向时空覆盖类感知任务的分配方法，解决移动群智感知中的冷启动及多任务有效并行分配问题，使其能够更好地应用于普适计算以改善人们的日常生活。

本文的主要贡献如下：

(1) 设计群组协作的任务分配框架。由云平台对参与者进行属性分析，选出群组领导节点与成员节点，以群组协作的方式代替单参与者进行任务分配，有效提升了群组任务的完成率。

(2) 提出偏好感知的社交群组生成方法。引入参与者间的社交关系生成社交群组，解决时空覆盖感知任务分配的“冷启动”问题。引入技能动态更新机制，动态更新参与者技能以更好地进行任务参与者选择。

(3) 提出效用优化的任务群组匹配方法。将平

台效用优化问题抽象建模为多感知任务-多社交群组间的匹配问题，并利用网络流模型进行任务-社交群组匹配决策，最大化感知平台效用。

2 问题建模

2.1 系统模型

本文考虑到时空覆盖类感知任务具有时间跨度大、空间范围广等特点，造成的单参与者感知模式不适用问题。首先基于社交网络理论，综合考虑时空覆盖任务特征智能生成任务群组执行感知任务，以群组模式替代单参与者模式，提升感知任务完成率。

感知任务分配拟主要由任务发布、属性分析、群组生成、群组任务分配和群组任务执行5个阶段组成。在任务请求者上传感知任务之后，平台会对已注册的新老参与者进行属性分析。假定感知参与者在平台注册时会上传自己的社交关系，因此感知平台中会出现新老参与者相互交替的情况。由于老参与者的属性维度比较齐全，可直接进行参与者的任务属性分析。而新参与者属性维度较欠缺，将会出现任务分发的问题。由于新老参与者之间普遍存在着社交关系，可以借助社交关系进行参与者的任务接收率分析，以解决参与者任务历史信息不足的情况。

在对新老参与者进行属性分析之后，每次针对特定的感知任务都会生成特定的感知社交群组。平台会采用所提社交群组生成方法，进行特定的领导节点与群组成员节点选取。在生成特定的感知社交群组之后，考虑到在城市感知等场景中，需要同时对多个区域进行感知。加之，大多数用户在社交网络中只有相对稀疏的社交关系^[8]，特别是对于那些与其他用户的社交关系很弱的新参与者，无法保证总能找到具有足够候选参与者的社交群组，需要设计相应的任务-社交群组匹配机制。平台采用所提任务群组匹配方法，根据任务及社交群组在参与者人数和预算方面的需求对社交群组进行整合生成任务群组。在生成任务群组之后，会将任务进行下发，任务群组在执行完感知任务之后，会上传感知数据到云平台。最后，由云平台下发相应的任务奖励。

2.2 问题建模

在移动群智感知系统中主要有3个部分即任务、平台和感知参与者。

定义1 (任务)： 主要指任务请求者上传的感知任务 $T = \{t_1, t_2, \dots, t_m\}$ ，表示有 $m(m \geq 2)$ 个感知子任务，每个子任务 t_i 可以表示为 $\langle B_{t_i}, r_{t_i}, \langle t_{i_start}, t_{i_end} \rangle \rangle$ 。具有以下定义：

(1) 对于 $\forall t_i \in T$ ，子任务的预算为 B_{t_i} ；

(2) 任务是时延容忍的，任务持续时间为 $\langle t_{i_start}, t_{i_end} \rangle$ ；

(3) 对于 $\forall t_i \in T$, 子任务的完成标准为至少招募到 $r_i (r_i \geq 2)$ 个参与者;

(4) 任务预算为参与者人数阈值与单位人数预算之积 $r_i \cdot l$ 。

定义2 (平台): 任务请求者将感知任务上传到平台, 感知平台具有老参与者的任务完成历史数据, 平台负责任务的分配和任务奖励的发布。

定义3 (感知参与者): 完成感知任务的参与者 $W = \{w_1, w_2, \dots, w_n\} = \{w_{\text{new}}, w_{\text{old}}\}$, 每个参与者 w_j 可以表示为 $\langle B_{w_j}, \langle w_{j_{\text{start}}}, w_{j_{\text{end}}} \rangle \rangle$, 有以下特点:

(1) 新老参与者在感知平台中交错, 每名参与者1次只能完成1种任务;

(2) 新参与者在注册时会上传自己的社交关系, 且参与者会有特定的在线时间即 $\langle w_{j_{\text{start}}}, w_{j_{\text{end}}} \rangle$;

(3) 参与者会有特定的任务完成成本, 对于 $\forall w_j \in W$, 参与者的任务成本为 B_{w_j} 。

定义4 (平台效用): 对于感知任务 $t_m \in T$, 任务的完成成本为 B_w , 任务的预算为 B_t , 则平台效用表示为二者之差, 平台的总效用可以表示为 $\text{uti}_{\text{platf}} = \sum_{i=1}^m (B_t - B_w)$ 。

本文假设参与者完成的感知任务类型为同构的。对于出现的多个感知子任务 $T = \{t_1, t_2, \dots, t_m\}$, 在对每个子任务以及参与者进行任务属性分析之后, 平台中会出现多个社交群组对应一个子任务的情况。其中, 总的社交群组为 $G^* = \{G_1, G_2, \dots, G_k\}$ ($k \gg m$), 本文采用 x_{ji} 表示群组 j 是否参与任务 i , 如果 x_{ji} 的值为1, 则表示群组 j 会参与完成任务 i 。反之, 则表示群组 j 不会参与到任务 i 的完成中。因此, 可以将任务-群组匹配(Task-Group Matching, TGM)问题建模为

$$\left. \begin{aligned} & \max \left(\sum_{i=1}^m B_{t_i} - \sum_{j=1}^k B_{w_j} \right) \\ & \text{s.t. } \sum_{G_k \in G^*} M_j x_{ji} \geq r_i, \forall t_i \in T \\ & \quad \sum_{G_k \in G^*} C_j x_{ji} \leq B_i, \forall t_i \in T \\ & \quad x_{ji} \in \{0, 1\} \end{aligned} \right\} \quad (1)$$

本文的优化目标为最大化平台效用, 如式(1)所示, 平台效用表现为任务完成的回报与完成任务的工人成本之差, 第1个约束表示对于每个感知任务 t_i 需要的参与者人数超过人数阈值 r_i , M_j 表示群组 j 的人数, 第2个约束表示参与每个感知任务 t_i 的人员成本不能超过任务预算 B_i 。

3 偏好感知的社交群组生成方法

本部分基于参与者间的社交关系提出偏好感知

的社交群组生成方法。任务发起者将任务上传感知平台之后到任务正式发布之前, 感知平台会充分分析任务与参与者的属性, 再针对特定的感知任务进行社交群组的生成。社交群组主要由领导节点与成员节点组成。感知平台会选择感知群组的领导节点, 在选出领导节点之后, 再进行群组成员节点的选取。群组领导节点主要在老参与者中进行选择, 原因在于老参与者的任务完成历史更加丰富。

3.1 领导节点选取

感知平台在选择参与者节点时(包括领导节点和群组成员节点)需满足任务周期在参与者的在线周期之内, 即 $\forall t_i \in T, \forall w_j \in W$, 有 $\langle t_{i_{\text{start}}}, t_{i_{\text{end}}} \rangle \subseteq \langle w_{j_{\text{start}}}, w_{j_{\text{end}}} \rangle$ 。在领导节点的选择过程中主要考虑以下3个因素。

定义5 (社交影响力): 领导节点的社交影响力

$$\text{Im}(w_j) = \frac{1}{M} |\cup_{w_j} F_j| \quad (2)$$

$|\cup_{w_j} F_j|$ 为参与者在社交网络社区上的好友数量, M 为感知区域潜在参与者总数。

定义6 (活跃度): 参与者在任务区域的活跃度

$$a(w_j, l) = \frac{f(w_j, t_i, \text{loc}) \times d(w_j, t_i, \text{loc})}{\sum_{i=1}^q f(w_j, t_i, \text{loc}) \times \sum_{i=1}^q d(w_j, t_i, \text{loc})} \quad (3)$$

$f(w_j, t_i, \text{loc}) \times d(w_j, t_i, \text{loc})$ 表示参与者 w_j 在特定任务空间位置上的累计访问频次与停留时长的乘积。 $\sum_{i=1}^q f(w_j, t_i, \text{loc}) \times \sum_{i=1}^q d(w_j, t_i, \text{loc})$ 则为参与者在过去的一段时间内访问的总的区域的累计访问频次与停留时长的乘积。移动行为特征反映参与者空间行为分布特征。本文选择参与者的空间出现频次与停留时间长度作为移动行为特征的刻画。

定义7 (感知能力水平): 参与者完成感知任务的能力。

对于新参与者, 本文考虑到在执行任务的过程中参与者自身的完成任务的能力会不断得到提升。因此, 设计一种参与者技能的更新机制是十分有必要的。具体的计算公式为

$$s'_{w_j} = \begin{cases} \frac{1}{\pi} \arctan(\gamma \times (s_{w_j} + q_i)) + \frac{1}{2}, & s_{w_j} < \lambda \\ \frac{1}{\pi} \arctan \left(\gamma \times \left(\sum_{k \in S} \frac{l_{u_j}^c}{l_{u_j}^k} + \lambda \right) \right) + \frac{1}{2}, & s_{w_j} \geq \lambda \end{cases} \quad (4)$$

其中, s_{new} 为任务执行前参与者的任务完成能力, $\gamma \geq 1$ 为更新系数。当其能力值达到阈值 λ 时, 表示该技能已被用户完全掌握, 并不再对其进行更新^[9]。

使用 $\text{dis}(x_i, x_j)$ 表示数据 x_i 与数据 x_j 的差异，簇心数据即为任务真值 x_r ，在任务真值为 x_r 的条件下，参与者 u_i 的数据质量^[10] 为 $q_i = 1/(\text{dis}(x_i, x_j) + 1)$ 。当参与者的能力达到阈值 λ 就不再对其进行更新，平台将会将参与者判定为老参与者。对于老参与者，由于其自身的能力水平比较固定，主要为感知参与者完成特定的感知任务占有所有完成任务的比例。 $l_{u_j}^c$ 表示参与者对某一种任务的完成次数， $\sum_{k \in S} l_{u_j}^k$ 表示参与者完成历史任务的总集合。

在完成上述属性值的计算之后，再利用等级效用函数进行参与者排名评估

$$R(w_j) = \text{Rank}(\text{Im}(w_j)) \times \text{Rank}(a(w_j, l)) \times \text{Rank}(s_{w_j}) \quad (5)$$

Rank函数表示候选参与者在相关属性的排名，分数越高的参与者排名越高。对上述3种因素采用乘法融合的方法^[11] 选出领导节点，并利用Top-K搜索选取领导节点，再根据领导节点的社交以及地理位置进行群组生成。

3.2 社交群组生成

感知平台在选出领导节点之后，以领导节点为源节点，通过领导节点的社交关系进行进一步的群组成员的选取。主要通过将领导节点建模为根节点，在其社交好友中进行进一步的感知参与者搜索。领导节点的好友中既有新参与者也会有老参与者，分别建模新老参与者的偏好来进行社交群组成员的选取，进一步，根据任务预算约束来招募群组感知参与者。

定义8 (老参与者任务接受率)：对于老参与者而言，特定任务的任务接受率可以表示为

$$\text{acc}_{u_j} = P_1 \times I(\text{prt}_{u_j}, I_{1\max}) \times I(\text{prd}_{u_j}, I_{2\max}) \times I(\text{pr}_{u_j}, I_{3\max}) \quad (6)$$

主要由3部分组成： $I(\text{prt}_{u_j}, I_{1\max})$ 表示参与者对任务类型的偏好， $I(\text{prd}_{u_j}, I_{2\max})$ 表示参与者对任务距离的偏好，感知任务的奖励激励则由 $I(\text{pr}_{u_j}, I_{3\max})$ 表示。本文采用 $I(x, I_{\max}) = (I_{\max} - 1)\sqrt{1 - (1 - x)^2} + 1$ 的方式来聚合任务类型以及距离偏好对参与者任务接收的影响^[12]。 P_1 为一个超参数， I_{\max} 表示预定义的概率递增上限。任务类型偏好与任务距离偏好定义为

$$\text{prt}_{u_j} = J(\text{task.con}, \text{task.his}) \quad (7)$$

$$\text{prd}_{u_j} = \alpha \times \exp(-\beta \times \text{dist}(u_j, \text{loc}_i)) \quad (8)$$

式(7)中任务类型偏好主要反映当前任务与参与者历史任务之间的相似度。利用Jaccard相似度来进行计算，如果当前任务更加贴合参与者的任务

偏好，则相应的任务接受率会更高。在任务距离偏好方面则主要考虑任务距离对参与者的任务接收的影响。 $\text{dist}(u_j, \text{loc}_i)$ 表示当前任务与参与者之间的距离， loc_i 表示参与者的历史签到经纬度的均值， α 为一个距离超参数。由于参与者往往倾向于就近进行任务感知，因此，通过量化任务与参与者活跃位置之间的距离可以更好地反映老参与者的任务接受率^[13]。

式(9)中， $f(\cdot)$ 为sigmoid函数，参与者在完成任务的过程中会有一个特定的初始任务成本 θ ，只有当任务回报大于任务成本时，参与者才会参与到感知任务中^[14]。

$$\text{pr}_{u_j} = \begin{cases} f(\text{task.rew} - \theta), & \text{task.rew} \geq \theta \\ 0, & \text{task.rew} < \theta \end{cases} \quad (9)$$

定义9 (新参与者任务接受率)：新参与者接收任务的概率可以表示为

$$\text{acc}_{u_j} = P_2 \times I(\text{prs}_{i,j}, I_{4\max}) \times I(\text{prd}_{u_j}, I_{5\max}) \times I(\text{pr}_{u_j}, I_{6\max}) \quad (10)$$

同理，由社交关系、任务距离以及任务奖励激励3部分组成。 P_2 为一个超参数， $I_{4\max} \sim I_{6\max}$ 表示预定义的概率递增上限。对于新参与者而言，平台没有感知参与者的任务完成历史。但是，参与者的感知行为在一定程度上受到其社交关系的影响，进而促使参与者参与特定的感知任务。因此，考虑参与者的社交关系对参与者感知行为的影响有利于提高感知任务的接收。同时，完成感知任务的回报也会影响参与者是否参与任务。由于参与者在完成感知任务的过程中，会付出一定量的劳动成本，如果完成任务所得的回报越高，那么参与者参与感知任务的概率也会相应的提高。相应的社交关系和奖励激励定义为

$$\text{prs}_{i,j} = \frac{N(u_i) \cap N(u_j)}{N(u_i) \cup N(u_j)} \quad (11)$$

式(11)主要通过Jaccard相似度来衡量两个参与者之间社交关系的强弱，本文通过分析好友的任务接受率来进一步推断特定参与者的任务接收率， $N(u_i)$ 表示参与者 u_i 的在线社交好友集合，如果参与者之间共享更多的相邻节点，则社交关系会更强。同时，在进行新参与者的招募时也应考虑任务奖励带来的影响。通过3.1节选出的leader节点为源节点，在其好友中进行广度优先遍历。由于领导节点的好友关系中会出现新老参与者共存的现象，因此需要分别计算每个好友参与者接收感知任务的概率，选择满足超过特定概率值的参与者，直到招募到足够的成员参与者。同时，在每次招募成员的过程中会动态地更新参与者成员的技能。

4 效用优化的任务群组匹配方法

感知平台在划分好社交群组之后,将会进行多感知任务并发的任务分配。因此,本文设计效用优化的任务群组匹配方法。

4.1 任务群组生成问题建模

定理1 TGM问题是NP-hard问题。

证明 本文将0-1背包问题转化为任务-群组匹配(Task-Group Matching, TGM)问题的一个特殊实例。

本文证明TGM问题等价于背包问题。假设利用 z_{ji} 表示群组 j 完成任务 i 得到的奖励,则奖励函数可以简化为 $z_{ji}x_{ji}$ 。进一步,将群组的人数看成背包的重量,群组二元决策变量 x_{ji} 看成物品是否放入背包 b_i ,则TGM问题可以退化为0-1背包问题^[15]。即会有如等式(12)成立

$$\left. \begin{aligned} \max \quad & \sum_{i \in M} z_{ji}x_{ji} \\ \text{s.t.} \quad & \sum_{G_k \in G^*} C_j x_{ji} \leq B_i, \forall t_i \in T \\ & x_{ji} \in \{0, 1\} \end{aligned} \right\} \quad (12)$$

由于已知0-1背包问题是非确定性多项式归约难(Non-deterministic Polynomial-hard, NP-hard)问题,则TGM问题至少也具有与0-1背包问题相同的复杂性。因此,TGM问题是NP-hard问题。

给定由前面3.2节生成的社交群组,用集合 $G^* = \{G_1, G_2, \dots, G_k\}$ 表示,假设每个社交群组都需要完成一系列的感知任务。第 k 个社交群组 G_k 可以完成的任务数量上限为 g_k 。与此同时,任务请求者同时发布了多个同种类型的感知任务 $T = \{t_1, t_2, \dots, t_m\}$,任意一个感知任务 t_m 最多会被 r_m 个参与者完成。在本文中,由于不同的社交群组有不同的任务参与者数量。因此,在任务匹配的过程中假设同一个群组可以参与多个感知任务,但是每个群组里面的参与者每次只能参与1个感知任务。本文利用 $GT_m = \{gt_{m1}, gt_{m2}, \dots\}$ 来表示参与完成感知任务 t_m 的社交群组集合。进一步,利用 $TG_k = \{tg_{k1}, tg_{k2}, \dots\}$ 来表示分配给社交群组 G_k 的任务集合, $C(TG_k)$ 是 G_k 完成任务的成本。那么TGM问题可以进一步表示为

$$\left. \begin{aligned} \max \quad & \sum_{i=1}^k |TG_i| \\ \min \quad & \sum_{j=1}^k C(TG_j) \\ \text{s.t.} \quad & |TG_i| \leq g_k (1 \leq i \leq k) \\ & |GT_m| \leq r_m (1 \leq j \leq m) \end{aligned} \right\} \quad (13)$$

解决TGM问题主要有两个挑战:一是每个社交群组可以同时完成多项感知任务;另一个是

TGM问题有两个优化目标。对于挑战1,社交群组与任务的匹配属于多任务分配问题,存在着多个群组与多个任务进行匹配的情况。对于挑战2,在两个优化目标中,在式(13)中第1个优化目标主要体现为最大化任务的完成数,第2个优化目标为最小化任务的完成成本。两个优化目标是相互矛盾的,不可能同时得到满足两个优化目标要求的最优解。然而,可以在完成的总任务数量和总任务成本之间进行权衡以达到目标。

4.2 任务群组生成

最小费用最大流(Minimum Cost Maximum Flow, MCMF)模型旨在找到一组成本最小、流量最大的最优路径。MCMF模型的流网络是有向图,其中每条边都有容量、流量和成本。边的容量表示为可以通过边的最大流量。为了对TGM问题进行求解,本文利用MCMF模型,将社交群组成员完成任务的花销代表成本,完成任务的总数被建模为流。由于流网络中不可能只有参与者节点和任务节点,以及需要在流网络中表示参与者和任务的不同需求,本文对MCMF模型进行了改进,具体的方法模型如图1所示。

对于源节点和社交群组节点之间的每条边的容量为 g_k ,这反映了每个社交群组最多可以同时执行 g_k 个任务。同时边的成本为0,因为源节点和群组节点之间的边仅用于流入流,没有产生成本。此外,从群组节点和任务节点流入汇聚节点的流量应该反映任务的完成。对于汇聚节点而言,总的最大流量为 $\sum_{l=1}^m r_l$,其中任务节点与汇聚节点之间的每条边的容量为 r_m ,边的成本为0。本文首先枚举所有可能的任务集合,将感知任务标号为1~ m 。任何一个任务都可以由来自多个群组的多个参与者执行。此外,群组节点和任务集节点之间的边的成本是任务的完成成本。最后,任务节点和汇聚节点之间的边的容量为 r_m ,因为一个感知任务最多可以由 r_m 个参与者同时执行。

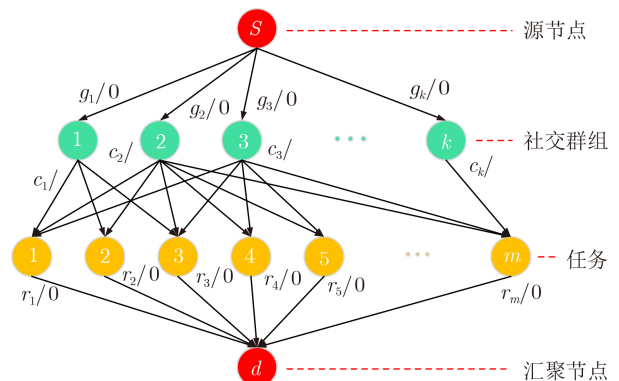


图1 TGM-MCMF算法模型图

TGM-MCMF算法包括两部分：一是构建MCMF模型的流网络；另一种是在流网络中寻找最优解。首先，导入由3.2节生成的社交群组集合 $\{G^*\}$ 以及任务集合 T 。接着，计算群组成员的任务参与成本 c_k ，成本主要指群组成员完成任务的成本，主要为群组参与者的任务初始成本以及通信成本。通信成本主要为群组成员 k 与群组领导节点 i 之间的社交关系跳数与单位跳数成本之积，以及两个群组领导节点之间的通信成本 ϑ ，因此可得 $c_k = \text{dis}_{ki} \times \text{unit}_{ki} + \theta_k + \vartheta$ 。然后，将流 f 初始化为0，在残差网络 G_f 中贪婪地选择增广路径 r^* 。沿 r^* 用 $c_f(r^*)$ 增广流 f ，直到残差网络 G_f 中没有增广路径。最后，输出任务群组集合 $\{M^*\}$ 以及完成的任务集合 T^* 。

感知平台在选出任务群组之后，会将相应的感知任务分发给每个社交群组的领导节点，由领导节点进行感知任务的进一步分发。在领导节点将任务发布给群组成员后，群组成员节点会到相应的任务区域完成感知任务。在任务完成后将任务结果反馈给领导节点，由领导节点将感知数据上传感知平台。最后，在感知平台将数据反馈给任务请求者之后，平台会将任务奖励下发给相应的群组成员节点。

5 仿真分析

5.1 数据集

本文主要在配备Intel Core i9-10900K以及Python 3.8语言的计算机上进行仿真实验。所用数据集为一个同时包含好友关系以及位置签到的Gowalla数据集。主要的仿真参数如表1所示。

5.2 对比算法与评估指标

本文主要采用3个算法进行对比实验，即面向群组的合作群智感知(Group-oriented Cooperative Crowdsensing, GoCC)^[1]算法、合作众包(Cooperative Crowdsourcing, C2)^[16]算法和忽略感知技能更新的最小费用最大流群组-任务匹配(Task-Group

Matching-Minimum Cost Maximum Flow-without prefer, TGM-MCMF-wp)算法。其中GoCC是以参与者的任务成本为导向的参与者选择算法，在算法中考虑参与者的任务成本以及社交偏好，忽略参与者的感知技能。C2则不考虑参与者的社交偏好，只考虑参与者的任务成本进行参与者选择。最后，TGM-MCMF-wp为不考虑参与者技能更新的算法变体。仿真指标主要有两个即平台效用与任务完成率。

(1) 平台效用

$$\text{uti}_{\text{platf}} = \sum_{i=1}^m B_t - \sum_{j=1}^k B_w \quad (14)$$

平台效用为已完成的所有感知任务的预算与成本的差值，本文的目标在于最大化感知平台的效用。

(2) 任务完成率

$$\text{tcr}_{\text{tas}} = \frac{\text{tas}_{\text{com}}}{\text{tas}_{\text{tot}}} \quad (15)$$

任务完成率主要为已完成的感知任务数量与总的感知任务数量的比值。

5.3 结果分析

从图2(a)可以看到随着感知任务数量的增加，TGM-MCMF, TGM-MCMF-wp, GoCC以及C2 4个算法的平台效用都呈上升趋势。由于考虑了参与者技能的更新，随着感知任务的不断推进，相较于TGM-MCMF-wp算法，在TGM-MCMF中将会有更多的新参与者成为老参与者以及成为领导节点，感知平台的效用也将会不断得到提升。因此，本文算法相较于TGM-MCMF-wp算法平均提升了17.4%，相较于GoCC平均提升了22.1%，相较于C2平均提升了41.7%。从图2(b)中可以看到随着感知任务数量的增加，4个算法的任务完成率都比较稳定。由于TGM-MCMF算法综合考虑了其他算法的因素，具有最高的任务完成率。因此，本文算法相较于TGM-MCMF-wp算法平均提升了8.2%，相较于GoCC平均提升了8.1%，相较于C2平均提升了18.4%。

图3为任务人数阈值 r_i 带来的影响。在图3(a)中，由于感知任务的完成标准为招募到超过任务人数阈值的参与者，所以当任务人数阈值 r_i 上升时，感知任务的完成难度也将不断上升。TGM-MCMF, TGM-MCMF-wp, GoCC以及C2 4个算法的平台效用都呈下降趋势。由于TGM-MCMF算法综合考虑了其他算法的因素，因此平台效用下降最为缓慢。本文算法相较于TGM-MCMF-wp算法平均提升了51.7%，相较于GoCC平均提升了30.3%。在图3(b)中，随着任务人数阈值 r_i 的增加，4个算法的任务

表1 实验参数

参数	值
任务接受率参数(α, β)	4, 0.5
老参与者的技能阈值(λ)	0.5
偏好超参数(P_1, P_2)	0.5
相关因素概率递增上限($I_{1\max} \sim I_{6\max}$)	1.5
参与者技能的更新参数(γ)	3
领导节点之间的通信成本(ϑ)	1
单位跳数的通信成本(unit_{ki})	0.5
任务的总周期(ψ)	[300, 800]
参与者在线时间窗口	[1, 10]

完成率都呈下降趋势。由于TGM-MCMF算法综合考虑了其他算法的因素，因此任务完成率下降最为缓慢，本文算法相较于TGM-MCMF-wp算法平均提升了8.0%，相较于GoCC平均提升了7.6%，相较于C2平均提升了12.8%。

从图4(a)可以看到随着参与者初始成本的增加，达到任务的人数阈值也将越来越困难，由于TGM-MCMF算法综合考虑了算法的相关因素。因此，相较于TGM-MCMF-wp算法平均提升了19.9%，相较于GoCC平均提升了16.9%，相较于C2平均提升了45.1%。从图4(b)中可以看到随着参与者初始成本的增加，任务的人数需求也将越来越难以满足，由于TGM-MCMF算法综合考虑了算法的相关因素。因此，本文算法相较于TGM-MCMF-wp算法平均提升了4.8%，相较于GoCC平均提升了4.9%，相较于C2平均提升了9.1%。

图5为单位人数预算*l*带来的影响。在图5(a)中，随着任务单位人数预算*l*的增加，平台具有更加充裕的预算，可以吸纳更多的任务参与者。因此4个算法的平台效用依次增加，相较于TGM-MCMF-wp算法平均提升了15.5%，相较于GoCC平均提升了18.4%，相较于C2平均提升了52.8%。在图5(b)中，随着任务单位人数预算*l*的增加，平台在进行

感知参与者招募时会更加灵活，会有更多的任务得到完成。因此，4个算法的任务完成率依次增加。本文算法相较于TGM-MCMF-wp算法平均提升了5.4%，相较于GoCC平均提升了6.8%，相较于C2平均提升了16.7%。

图6为4个算法的运行时间对比，主要考虑了感知任务数量和任务人数阈值 r_i 带来的影响。通过从签到数据集中的密集区域随机选取500~2500个任务区域进行任务分配，1~25随机生成任务阈值。从图6(a)中可以看到随着感知任务数量的不断增加，4个算法的运行时间皆呈上升趋势。相较于TGM-MCMF-wp算法，TGM-MCMF通过进行参与者的技能更新，以更低的成本生成更多的社交群组。TGM-MCMF相较于GoCC通过对参与者感知技能的评估，保证更高的任务完成率。而C2仅以成本为导向，则花费了最低的算法运行时间。从图6(b)中可以看到随着任务阈值的不断增加，4个算法的运行时间皆呈上升趋势。TGM-MCMF相较于基线算法在参与者的技能偏好、社交偏好以及参与者技能更新方面进行综合评估，因此在社交群组的生成过程中将会花费更多的计算时间以满足感知任务的阈值需求，在更多计算开销的情况下，得到了最高的平台效用与任务完成率。




图2 感知任务数量带来的影响

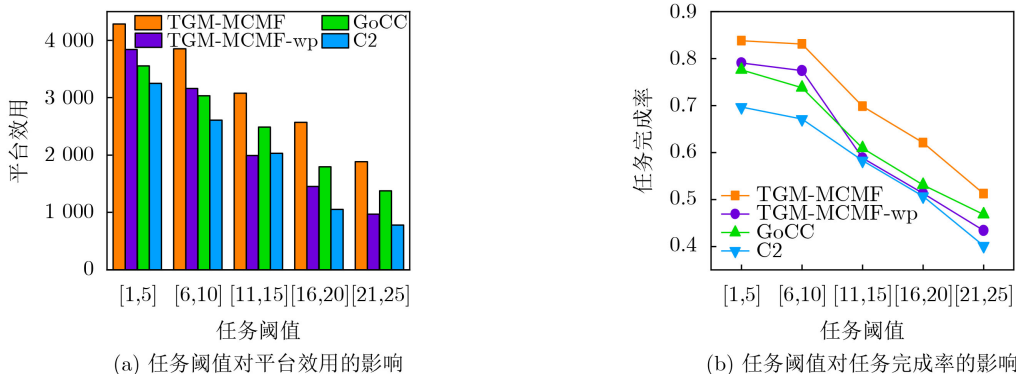


图3 任务阈值带来的影响

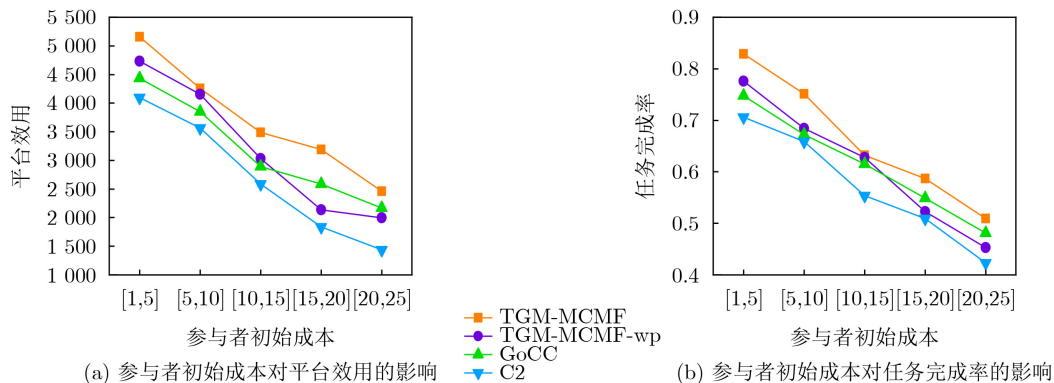


图 4 参与者初始成本带来的影响

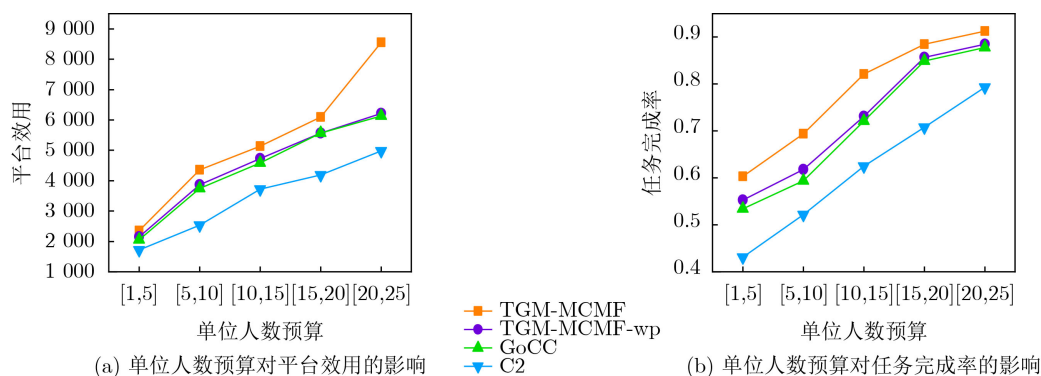


图 5 单位人数预算带来的影响

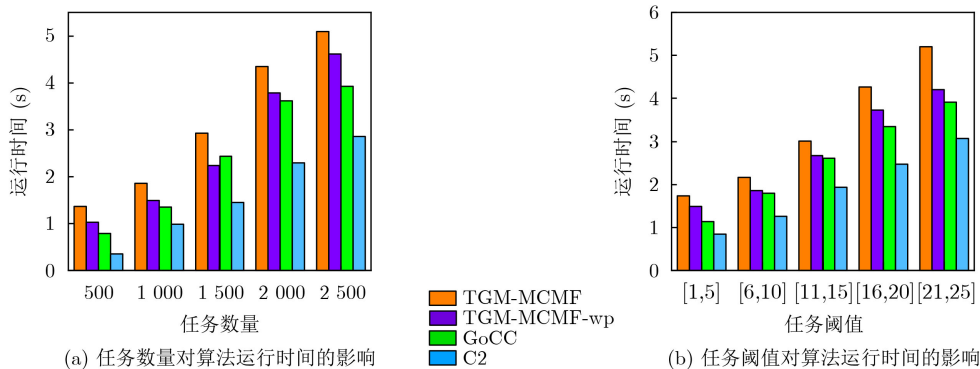


图 6 算法运行时间对比

在时间复杂度方面，对于参与者集合 W ，群组任务集合 T ，在群组领导节点的生成过程中，感知平台需逐一对参与者进行属性评估，相应的时间复杂度为 $O(|W|^2)$ 。在群组成员的生成过程中，这一过程需要搜索领导节点的社交好友，由于参与者群组的数量大于感知任务的数量，因此，在 k 个领导节点的情况下相应的时间复杂度为 $O(k \cdot |T| \cdot |W| \cdot \log_2 |W|)$ 。在任务群组的生成过程中，由于图的节点数量为 $m + k$ ，算法的时间复杂度为 $O(k^2(m + k))$ [2]。

6 结束语

本文研究了移动群智感知中的群组任务分配问

题，在面对需要多个参与者的时空覆盖类感知任务时，通过招募感知群组来完成感知任务。针对当前的大多数任务分配文献在面对新参与者历史信息不足时出现的任务分配问题，通过对新老参与者的社交关系进行评估生成社交群组。在社交群组生成之后，利用网络流理论来进行社交群组-感知任务的 2 次匹配以最大化感知平台的效用和任务完成率。至于未来的研究工作，将会进一步考虑参与者的激励问题，例如针对新成立的感知平台设计相应的参与者激励机制以扩大参与者用户池，以及在感知任务的完成过程中的参与者隐私保护问题。

参考文献

- [1] TAN Wenan, ZHAO Lu, LI Bo, *et al.* Multiple cooperative task allocation in group-oriented social mobile crowdsensing[J]. *IEEE Transactions on Services Computing*, 2022, 15(6): 3387–3401. doi: [10.1109/TSC.2021.3086097](https://doi.org/10.1109/TSC.2021.3086097).
- [2] WANG Jiangtao, WANG Feng, WANG Yasha, *et al.* HyTasker: Hybrid task allocation in mobile crowd sensing[J]. *IEEE Transactions on Mobile Computing*, 2020, 19(3): 598–611. doi: [10.1109/TMC.2019.2898950](https://doi.org/10.1109/TMC.2019.2898950).
- [3] WANG Zhibo, ZHAO Jing, HU Jiahui, *et al.* Towards personalized task-oriented worker recruitment in mobile crowdsensing[J]. *IEEE Transactions on Mobile Computing*, 2021, 20(5): 2080–2093. doi: [10.1109/TMC.2020.2973990](https://doi.org/10.1109/TMC.2020.2973990).
- [4] TAO Xi and SONG Wei. Profit-oriented task allocation for mobile crowdsensing with worker dynamics: Cooperative offline solution and predictive online solution[J]. *IEEE Transactions on Mobile Computing*, 2021, 20(8): 2637–2653. doi: [10.1109/TMC.2020.2983688](https://doi.org/10.1109/TMC.2020.2983688).
- [5] XU Jia, RAO Zhengqiang, XU Lijie, *et al.* Incentive mechanism for multiple cooperative tasks with compatible users in mobile crowd sensing via online communities[J]. *IEEE Transactions on Mobile Computing*, 2020, 19(7): 1618–1633. doi: [10.1109/TMC.2019.2911512](https://doi.org/10.1109/TMC.2019.2911512).
- [6] ZHAO Yan, ZHENG Kai, YIN Hongzhi, *et al.* Preference-aware task assignment in spatial crowdsourcing: From individuals to groups[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(7): 3461–3477. doi: [10.1109/TKDE.2020.3021028](https://doi.org/10.1109/TKDE.2020.3021028).
- [7] LEI Yu, WANG Zhitao, LI Wenjie, *et al.* Social attentive deep Q-networks for recommender systems[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(5): 2443–2457. doi: [10.1109/TKDE.2020.3012346](https://doi.org/10.1109/TKDE.2020.3012346).
- [8] ZHAO Yiming, SONG Wei, and HAN Zhu. Social-aware data dissemination via device-to-device communications: Fusing social and mobile networks with incentive constraints[J]. *IEEE Transactions on Services Computing*, 2019, 12(3): 489–502. doi: [10.1109/TSC.2016.2599160](https://doi.org/10.1109/TSC.2016.2599160).
- [9] WANG Wendong, GAO Hui, LIU C H, *et al.* Credible and energy-aware participant selection with limited task budget for mobile crowd sensing[J]. *Ad Hoc Networks*, 2016, 43: 56–70. doi: [10.1016/j.adhoc.2016.02.007](https://doi.org/10.1016/j.adhoc.2016.02.007).
- [10] WU Fan, YANG Shuo, ZHENG Zhenzhe, *et al.* Fine-grained user profiling for personalized task matching in mobile crowdsensing[J]. *IEEE Transactions on Mobile Computing*, 2021, 20(10): 2961–2976. doi: [10.1109/TMC.2020.2993963](https://doi.org/10.1109/TMC.2020.2993963).
- [11] OGUNDELE T J, CHOW C Y, and ZHANG Jiadong. SoCaST: Exploiting social, categorical and spatio-temporal preferences for personalized event recommendations[C]. The 14th International Symposium on Pervasive Systems, Algorithms and Networks & 2017 11th International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing (ISPAN-FCST-ISCC), Exeter, UK, 2017: 38–45. doi: [10.1109/ISPAN-FCST-ISCC.2017.68](https://doi.org/10.1109/ISPAN-FCST-ISCC.2017.68).
- [12] LI Ji, CAI Zhipeng, YAN Mingyuan, *et al.* Using crowdsourced data in location-based social networks to explore influence maximization[C]. The 35th Annual IEEE International Conference on Computer Communications, San Francisco, USA, 2016: 1–9. doi: [10.1109/INFOCOM.2016.7524471](https://doi.org/10.1109/INFOCOM.2016.7524471).
- [13] WANG Liang, YANG Dingqi, YU Zhiwen, *et al.* Acceptance-aware mobile crowdsourcing worker recruitment in social networks[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(2): 634–646. doi: [10.1109/TMC.2021.3090764](https://doi.org/10.1109/TMC.2021.3090764).
- [14] ZHAO Lu, TAN Wenan, LI Bo, *et al.* Multiple cooperative task assignment on reliability-oriented social crowdsourcing[J]. *IEEE Transactions on Services Computing*, 2022, 15(6): 3402–3416. doi: [10.1109/TSC.2021.3103636](https://doi.org/10.1109/TSC.2021.3103636).
- [15] XU Chenghao and SONG Wei. Efficient data uploading for mobile crowdsensing via team collaborating and matching[J]. *IEEE Transactions on Green Communications and Networking*, 2022, 6(1): 645–654. doi: [10.1109/TGCN.2021.3109740](https://doi.org/10.1109/TGCN.2021.3109740).
- [16] LUO Shuyun, SUN Yongmei, WEN Zhenyu, *et al.* C2: Truthful incentive mechanism for multiple cooperative tasks in mobile cloud[C]. 2016 IEEE International Conference on Communications (ICC), Kuala Lumpur, Malaysia, 2016: 1–6. doi: [10.1109/ICC.2016.7511052](https://doi.org/10.1109/ICC.2016.7511052).

吴大鹏: 男, 教授, 研究方向为泛在无线网络、社会计算等。

管 芑: 男, 硕士生, 研究方向为移动群智感知。

张普宁: 男, 副教授, 研究方向为物联网搜索等。

杨志刚: 男, 博士, 研究方向为隐私计算等。

王汝言: 男, 教授, 研究方向为泛在网络、多媒体信息处理等。

责任编辑: 余 蓉