

# 移动群智感知中基于协同排序的任务推荐方法

王 健<sup>1</sup>, 刘嘉欣<sup>1</sup>, 赵国生<sup>2</sup>, 赵中楠<sup>1</sup>

(1. 哈尔滨理工大学计算机科学与技术学院, 黑龙江哈尔滨 150080; 2. 哈尔滨师范大学计算机科学与信息工程学院, 黑龙江哈尔滨 150025)

**摘 要:** 针对移动群智感知中参与者积极性不高导致的数据质量低和激励成本高的问题, 本文提出了一种基于混合用户模型与列表级排序学习算法相结合的协同排序任务推荐方法. 根据参与者的历史行为对其进行分析, 初步过滤掉一些劣质感知用户, 同时利用参与者间的相似性构建混合用户模型. 利用概率矩阵分解对参与者的意愿值进行预测, 并根据排序学习得到一个排序模型. 根据排序模型生成任务推荐列表, 作为目标参与者的优选任务列表. 基于真实数据集的仿真实验结果表明, 本文提出的方法有效地提高了任务分配的准确率, 与此同时减少了感知用户的移动距离.

**关键词:** 移动群智感知; 任务推荐; 协同排序; 混合用户模型; 参与者意愿

**中图分类号:** TP393 **文献标识码:** A **文章编号:** 0372-2112(2021)10-2012-08

**电子学报 URL:** <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20200218

## Task Recommendation Method Based on Collaborative Ranking in Mobile Crowd Sensing

WANG Jian<sup>1</sup>, LIU Jia-xin<sup>1</sup>, ZHAO Guo-sheng<sup>2</sup>, ZHAO Zhong-nan<sup>1</sup>

(1. School of Computer Science and Technology, Harbin University of Science and Technology, Harbin, Heilongjiang 150080, China;

2. College of Computer Science and Information Engineering, Harbin Normal University, Harbin, Heilongjiang, 150025, China)

**Abstract:** To solve the problem of low data quality and high incentive cost caused by the inactivity of participants in mobile crowd sensing, this paper proposes a task recommendation method. We could analyze the participants according to their historical behavior, and filter out low-quality sensing users. Meanwhile, the similarity among the participants was used to build a user-hybrid model. Then, the participants' willingness would be predicted by the probabilistic matrix factorization, and a ranking model was obtained. Finally, a task recommendation list was generated on the basis of ranking model as the preferred task list for the target participants. The simulation experiments based on the real dataset show that the proposed method in this paper can improve the accuracy of task assignment effectively and reduce the moving distance of sensing users simultaneously.

**Key words:** mobile crowd sensing; task recommendation; collaborative ranking; user-hybrid model; participants' willingness

## 1 引言

移动群智感知(Mobile Crowd Sensing, MCS)<sup>[1]</sup>是指通过利用物理空间中的智能移动设备传感器以及网络空间中的移动社交网络收集用户贡献的数据. 其由于固有的高移动性和可扩展性, 已被许多传感应用广泛使用<sup>[2]</sup>. 在移动群智感知系统中, 影响感知数据质量的因素诸多, 其中最直接的影响因素是提供感知数据的参与者, 因此如何进行准确高效的任务分配是值得研究的问题. 为了令感知用户快速地获得适合自身的任

务, 参与者意愿是尤为重要的待分析因素. 如图 1 所示, 假如现有用户  $w_1, w_2, w_3$  和感知任务  $t_1, t_2, t_3$ , 每个任务类型及感知用户偏好不同. 若仅面向感知任务, 实际分配结果为  $\{w_1, t_2\}, \{w_2, t_1\}$  和  $\{w_3, t_3\}$ . 其中, 只有  $w_1$  被分配了与其意愿相匹配的任务, 而  $w_2$  和  $w_3$  则因被分配到不合适的任务, 不可避免地造成感知成本高或参与积极性差等现象, 导致感知数据质量不佳. 因此, 在 MCS 任务分配中, 对用户意愿进行充分且准确的分析, 令其意愿项与待分配任务最大程度地进行匹配, 将有

收稿日期: 2020-02-28; 修回日期: 2020-09-28; 责任编辑: 孙瑶

基金项目: 国家自然科学基金(No.61403109, No.61202458); 高等学校博士学科点专项科研基金(No.20112303120007); 黑龙江省自然科学基金(No.LH2020F034)

效地提高任务分配效率,同时提高感知数据的质量。

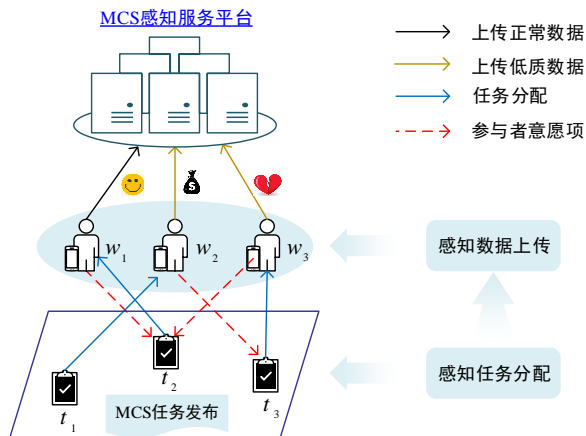


图1 参与者意愿与MCS任务分配关系实例

推荐技术的流行给用户的获取和选择行为提供了合理的首选项<sup>[3]</sup>,受此启发,本文不再局限于传统的任务分配方式,而是尝试以一种新颖的个性化推荐模式进行任务分配。本文提出了一种基于混合用户模型与列表级排序学习算法相结合的协同排序任务推荐方法(Task Recommendation with User-Hybrid Model and Collaborative Ranking, TR-UMCR)。首先,通过收集用户的隐式反馈信息进行用户过滤。然后,从两方面进行用户分析,通过相似度计算并构建混合用户模型,以确定近邻用户。最后,利用改进的排序学习算法训练得到排序模型,从而生成推荐列表推送给用户以供选择。基于上述研究目标和挑战,本文的贡献有:

(1)通过对基于历史行为隐式反馈信息的量化,对用户进行细粒度剖析,实现低质用户筛选;

(2)首次提出MCS任务推荐理念,以保证用户快速高效地找到正确的匹配任务,从而帮助任务发布者获得高质量的感知数据;

(3)基于协同过滤确定近邻用户,优化排序学习中的损失函数,实现感知任务排序列表优化,进一步提高MCS任务推荐的准确性。

## 2 相关工作

在移动群智感知现有的研究中,主要从任务组织者的角度(如任务时空覆盖、完成任务数量、预算约束等)优化任务分配过程。Xiong等人<sup>[4]</sup>提出的MCS任务分配框架iCrowd,以及Wang等人<sup>[5]</sup>提出的MCS参与者选择方法,目标都是最大化MCS任务覆盖率。Liu等人<sup>[6]</sup>提出了一个参与者选择框架TaskMe,以达到最小化成本和最大化完成任务数的目的。文献[7]中利用异构任务间的隐式时空相关性,提出了一种两阶段HMTA问题求解方法,有效地处理共享资源池中的多个并发任务。安健等人<sup>[8]</sup>利用公交载体轨迹可预测,活动覆盖

范围大等优势进行任务扩散,降低了感知用户的参与成本。但是现有研究往往忽略了参与方因素,如任务类型偏好、空间移动规律等很少被考虑在内。

由于参与者设备配置以及移动行为习惯的差异性,其对不同种类任务的接受度是有差异的。文献[9~11]都是基于预测位置来进行高效的用户招募以达到最小化移动成本的目的。其中,文献[9]提出的贪心离线算法g-MUS,在异构任务环境下进行了参与者优选,实现了参与人数约束下最大化任务完成数的目标。文献[12]针对参与感知用户群的非确定性,通过动态确定参与者子集以最小化感知成本。Pournajaf等人<sup>[13]</sup>提出一种能够动态适应用户的移动特性的任务分配方法。文献[14]提出了一个参与式传感任务分配框架PSTasker,虽然文中对参与者属性进行了考虑,但是忽略了参与者之间的关联。文献[15]提出了一种GSMS算法,不仅考虑了用户偏好,还在用户和任务之间引入Gale-Shapley博弈方法进行匹配,以达到最大化用户满意度的目标。但是这将消耗过多能耗,算法效率较低。由此可见,如何在考虑任务异质性和参与者复杂性的情况下进行合理且高效的分配,是具有挑战性的。

现有的MCS任务分配方法通常根据感知任务的地点和时效性,招募附近的感知节点来完成感知任务,缺乏考虑感知节点的自身意愿与能力。当面临复杂且庞大的感知任务体系时,由于节点感知能力动态性和有限性等问题,会伴随大量冗余数据的产生,重复感知、片面感知的信息一并上载到数据中心,不仅会影响感知质量,而且平台开销也会增大。

## 3 问题定义

为了提高群智感知系统中任务分配的总效用,本文提出了一种基于协同排序学习的任务推荐框架。在研究中通过对基于历史行为隐式反馈信息的量化,如用户历史签到记录、签到规律等,实现低质用户过滤。假设过滤后的感知用户池不存在恶意用户,且旨在以用户意愿为中心的感知任务分配过程中,可有效提升感知任务的完成效率和完成质量。现在已知有 $N$ 个感知任务 $T = \{t_1, t_2, \dots, t_j, \dots, t_n\}$ ,由于任务类型的差异将导致收集数据的方式不同,假设任务类型维度为 $d$ ,即 $S = \{s_1, s_2, \dots, s_k, \dots, s_d\}$ ,若平台上有 $M$ 个用户 $W = \{w_1, w_2, \dots, w_i, \dots, w_m\}$ ,用 $LW_i = \{l_{i1}, l_{i2}, l_{i3}, \dots\}$ 表示用户 $w_i$ 的首选任务集合。

MCS任务推荐问题描述如图2所示,通过三个阶段即训练阶段、排序阶段和推荐阶段,进行任务的合理分配。其中,训练阶段中利用参与者过去接受任务的记录信息,与任务所划分的特征进行匹配,并按偏好程度进

行排序,得到一个排序模型.排序阶段则可利用该模型对目标参与者可能喜欢的任务进行预测和排序,并结合现有任务集合生成推荐列表.最后,将排序结果推荐给目标参与者,实现任务的合理分配.

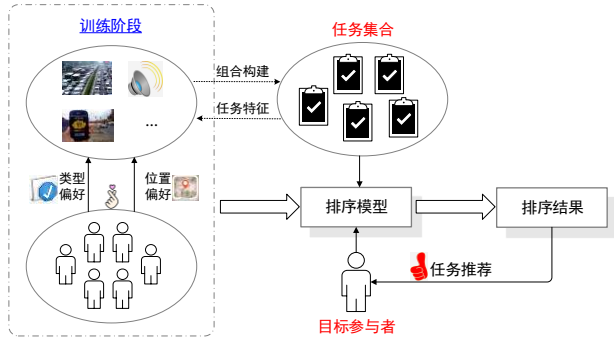


图2 MCS任务推荐问题描述

#### 4 基于协同排序的MCS任务推荐方法

基于协同排序的MCS任务推荐框架主要由混合用户模型和推荐模型组成,混合用户模型可以进行低质参与者过滤以及近邻用户确认,推荐模型可以增强推荐列表中任务之间的排序关系,最终达到最大化分配准确率和最小化移动成本的目的.

##### 4.1 混合用户模型

本文将参与者体现的隐式反馈信息转化为相应评分值(如参与者接受该类型任务的次数),并参照文献[16]的众包系统中用户的行为转化评分标准,结合本文问题需求,将体现参与者意愿程度的评分值分为5个等级.将量化用户行为得到相应的特征值用于进行用户过滤,并构建混合用户模型.基于上述情况,定义以下概念.

**定义1(用户信誉值)** 根据用户的历史行为进行映射,取每个用户接受数量最多的 $d$ 类任务(被用户所接受的任务类型维度相同,依据实验数据 $d$ 值由接收任务类型最少的用户决定),计算其接受的不同类型任务数量累乘,再与未完成任务数量相比得到用户信誉值,具体如式(1)所示:

$$R_i = \frac{\prod_{k=1}^d T_{ik}}{\sum_{j=1}^N T_{ij}} \quad (1)$$

其中, $T_{ik}$ 表示参与者 $i$ 接受 $k$ 类型任务的数量; $T_{ij}$ 表示参与者 $i$ 完成任务 $n$ 的状态,完成时状态为0,未完成状态为1.因此,当参与者随意选择感知任务时分子较小,未完成感知任务数量较多时分母较大,此时信誉值将偏低.

**定义2(用户移动特征)** 指用户在不同时间段内,对不同空间位置上任务的处理状态,体现了用户移动

轨迹的分布特征.具体如式(2)所示:

$$O_{iq} = \frac{f(w_i, l_q)}{f(w_i, l)} \times \frac{d(w_i, l_q)}{d(w_i, l)} \quad (2)$$

其中, $O_{iq}$ 表示用户 $w_i$ 在空间 $l_q$ 上的行为特征; $f(w_i, l_q)$ 和 $d(w_i, l_q)$ 表示用户 $w_j$ 在空间位置 $l_q$ 上的访问次数和停留时间; $f(w_i, l)$ 和 $d(w_i, l)$ 表示在所有位置的访问总次数和停留时间.

**定义3(用户意愿值)** 意愿值是对用户面向不同类型任务时,所体现出来的接受度和完成度的刻画.可将用户意愿特征值表示如式(3):

$$R_{ij} = \{r_{i1}, r_{i2}, r_{i3}, \dots, r_{ij}\} \quad (3)$$

其中, $r_{ij}$ 为用户 $w_i$ 对任务 $t_j$ 的偏好程度,取值范围是 $[0, 1]$ .可将参与者的意愿分为五个等级1、2、3、4、5映射到 $[0, 1]$ 中.

通过对用户历史行为的分析,可以初步了解用户的偏好,从任务类型和任务地点两个角度覆盖用户意愿.因此,通过引用余弦相似定理,利用得到的特征值,可以进行用户相似度计算.式(4)和式(5)分别计算了用户任务类型和空间位置的偏好相似度.

$$\text{sim}_{\text{category}}(W_a, W_b) = \frac{\sum_{j=1}^N r_{aj} * r_{bj}}{\sqrt{\sum_{j=1}^N r_{aj}^2} * \sqrt{\sum_{j=1}^N r_{bj}^2}} \quad (4)$$

$$\text{sim}_{\text{location}}(W_a, W_b) = \frac{\sum_{q=1}^Q o_{aq} * o_{bq}}{\sqrt{\sum_{q=1}^Q o_{aq}^2} * \sqrt{\sum_{q=1}^Q o_{bq}^2}} \quad (5)$$

用户之间总相似度计算如式(6)所示,通过调节式中 $\alpha$ 的值,来调节由任务类型偏好和空间位置偏好得到的用户相似度的比重.

$$\text{sim}(W_a, W_b) = \alpha \text{sim}_{\text{category}}(W_a, W_b) + (1 - \alpha) \text{sim}_{\text{location}}(W_a, W_b) \quad (6)$$

##### 4.2 推荐模型

本文采用基于列表级的排序学习方法<sup>[17]</sup>,从整个列表的角度出发提升推荐列表的准确性.针对用户个性化数据相对缺乏的情况,推荐模型结合概率矩阵分解方法<sup>[18]</sup>对稀疏矩阵进行补全,使得目标用户在历史数据不足的情况下,也能得到高精度的预测结果.基于列表级排序学习算法ListRank-MF<sup>[19]</sup>,本文提出一种融合近邻信息的改进算法.该算法中相关定义如下.

**定义4(PMF框架)** 概率矩阵因子分解(Probabilistic Matrix Factorization, PMF)是由观察到的评分、用户评分先验和任务评分先验的条件分布概率推断来制

定的. 最终PMF框架如式(7)所示:

$$U, V = \arg \min_{U, V} \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^N I_{ij} (R_{ij} - g(U_i^T V_j))^2 + \frac{\lambda_U}{2} \|U\|_F^2 + \frac{\lambda_V}{2} \|V\|_F^2 \quad (7)$$

其中,  $I_{ij}$  为指标函数, 表示用户  $i$  对任务  $j$  有兴趣的行动, 即当  $R_{ij} > 0$  时为 1, 否则为 0;  $g(x)$  是限定  $U_i^T V_j$  范围的逻辑函数, 即  $g(x) = \frac{1}{1 + \exp(-x)}$ ; 矩阵  $U$  和  $V$  为两个包

含用户和任务潜在特征的低秩矩阵;  $\|\cdot\|_F$  表示 Frobenius 范数;  $\lambda_U$  和  $\lambda_V$  分别为两个隐含特征矩阵的正则化参数.

**定义 5 (Top-one 概率)** 表示在给定的排名列表中, 某项排在首位的概率. 即目标用户  $i$  的任务排序列表  $l_i$  (例如, 有  $K$  个项目) 中, 一个被评为  $R_{ij}$  的项目的前一个概率可以如式(8)所示:

$$P_{l_i}(R_{ij}) = \frac{\varphi(R_{ij})}{\sum_{k=1}^K \varphi(R_{ik})} \quad (8)$$

其中,  $\varphi(x)$  可以是任何严格单调递增的函数, 并且所有  $x$  必须满足  $\varphi(x) > 0$ . 为简单起见, 采用与文献[20]相同的形式, 即令指数函数  $\varphi(x) = e^x$ .

**定义 6 (损失函数)** 利用训练样本列表中各项目的 Top-one 概率的交叉熵和排序模型(MF)中的排序列表进行构造的同时, 考虑近邻用户之间的影响, 最终损失函数如式(9)所示:

$$L(U, V) = \sum_{i=1}^M \left\{ - \sum_{j=1}^N P_{y^{(i)}}(R_{ij}) \log \left( P_{z^{(i)}} \left( g \left( U_i^T V_j \right) \right) \right) \right\} + \frac{\lambda}{2} \left( \|U\|_F^2 + \|V\|_F^2 \right) + \frac{\lambda_M}{2} \sum_{i=1}^M \sum_{f=1}^{|K \text{ neighbors of } i|} \text{sim}(i, f) \|U_i - U_f\|_F^2 \quad (9)$$

其中,  $P_{y^{(i)}}$  和  $P_{z^{(i)}}$  分别表示用户  $i$  的已知任务列表和预测任务列表的 Top-one 概率分布;  $|K \text{ neighbors of } i|$  表示目标用户  $i$  的最近  $K$  个邻居的集合;  $\text{Sim}(i, f)$  是用户  $i$  和用户  $f$  的相似度, 由式(6)计算得到;  $U_i$  和  $U_f$  分别表示用户  $i$  和用户  $f$  潜在在偏好的特征向量. 这个正则化项用来衡量目标用户与近邻用户在用户特征向量上的距离.

最后, 通过梯度下降算法更新  $U$  和  $V$  的特征向量, 进而将用户和任务特征向量的点乘运算作为效用函数来对测试用户产生推荐列表. 优化后的 TR-UMCR 算法既融合了 ListRank-MF 中要求预测任务列表的排序和真实任务列表排序相近的特点, 又融合了通过混合用户模型得到的近邻信息, 能够进一步提升算法性能. 由于 TR-UMCR 算法可以相对准确地预测出参与者对任务的偏好程度, 所以在此基础上进行 MCS 任务分配

会更加准确、高效.

## 5 仿真实验与分析

为了对本文方法的有效性进行验证, 采用仿真和真实数据集相结合的方式在 MATLAB R2018a 平台环境下进行实验. 对实验中的相关参数进行讨论, 从任务分配准确率和运行时间两方面进行性能分析, 同时比较了用户的参与成本与积极性.

### 5.1 实验设置

TR-UMCR 算法的分析与验证需要的数据集应包含大量的用户移动轨迹信息以及用户对任务的评分信息. 因此, 本文基于 Gowalla 数据集<sup>[20]</sup>的签到信息和众包平台的实际数据<sup>[21]</sup>进行了实验, 其中涉及的数据信息如表 1 所示.

表 1 实验数据集信息

Gowalla 数据集			交互数据集		
Candidates	Tasks	Check-in	Candidates	Tasks	Records
200	1023	9712	200	1000	6580

从中随机抽取 80% 的数据作为训练集, 20% 的数据作为测试集. 此外, 实验中涉及的参数设置如表 2 所示. 其中,  $c$  是指候选者的人数变化,  $t$  是指任务的数量变化,  $\alpha$  是相似度模型中的调节参数,  $\mu$  是学习速率,  $\lambda$  是正则化参数, iterations 是迭代次数. 为了保证模型的最优状态, 将对相关参数进行讨论, 取最优值进行实验. 因为实验数据中任务数量较多, 故将特征值即任务类型数目设置为 30.

表 2 实验参数设置

Parameter	Setting
$c$	0~200
$t$	0~1000
$\alpha$	0~1
$\lambda$	0.001~1
$\mu$	0.001~0.1
iterations	0~200
rank	30

为了验证本文所提方法的有效性, 将 TR-UMCR 算法与改进前的 ListRank-MF 算法相比较, 并选择现有研究中的 g-MUS 算法<sup>[9]</sup>和 GSMS 算法<sup>[15]</sup>作为基线方法. 主要从任务的分配准确性、任务分配效率以及激励效果三方面进行比较, 并讨论了参数对实验结果的影响.

### 5.2 实验结果分析

#### 5.2.1 参数分析

由于推荐模型是保障任务列表质量的关键, 本文对模型中学习速率  $\mu$  和正则化系数  $\lambda$  的取值进行了讨论, 观察不同取值情况下, 损失函数值随迭代次数的变

化,从而判断不同参数值对损失函数收敛性的影响,实验结果分别如图3和图4所示.因为本文方法从用户的任务类别偏好和任务位置偏好两方面进行用户意愿分析,因此对调节这两者比重的 $\alpha$ 参数进行讨论,分析结果如图5所示.根据实验结果,本文实验将学习速率 $\mu$ 设置为0.01,正则化系数 $\lambda$ 设置为0.01,迭代次数iterations设置为100,参数 $\alpha$ 值设置为0.5.




图3 学习速率对损失函数收敛性的影响




图4 正则化系数对损失函数收敛性的影响




图5 参数 $\alpha$ 对平均分配准确率的影响

### 5.2.2 性能比较


任务分配准确率作为评价算法整体分配效果的重

要指标,由推荐列表中任务的命中个数决定,即每个用户的推荐列表中,推荐成功的任务数在实际任务列表中占的比重.假设用户的任务推荐列表长度为 $G$ ,具体定义如式(10)所示:


$$PR_{(i)} = \frac{\sum_{g=1}^G l_{ig}}{LT_{(i)}} \times 100\% \quad (10)$$

其中, $LT_{(i)}$ 表示感知用户 $i$ 的实际任务列表长度; $l_{ig}$ 表示用户 $i$ 的推荐列表中第 $g$ 个位置的任务命中状态,若推荐任务被用户 $i$ 接受并完成,则 $l_{ig} = 1$ ,否则为0.

不同数据集下任务分配准确率的实验结果如图6和图7所示.图中展示了任务分配准确率随候选者和任务数量的变化,实验结果表明,TR-UMCR算法分配的准确率明显高于基线方法,并且稳定性更好.图6(a)和图7(a)显示任务分配准确率随候选者人数的变化,可以看出,4种方法的分配准确率呈现出不同程度的上升趋势.这是因为群智感知任务中,参与人数的多少决定任务的完成率.由图可知,TR-UMCR算法相比其他方法的分配效果受人影响较小,并且同等候选人数下,TR-UMCR算




(a)




(b)

图6 Gowalla数据集:平均分配准确率与候选者和任务数的关系比较

法准确率明显提高. 图 6(b)和图 7(b)显示,随着任务数量的增加,4种方法的分配准确率波动较小. 同等任务数量下,本文方法的分配效率明显高于g-MUS和ListRank-MF且略高于GSMS,整体准确率在96%左右.



(a)




(b)


图 7 交互数据集:平均分配准确率与候选者和任务数的关系比较

任务分配效率指的是任务分配的速度, 本文将其量化为分配阶段的算法运行时间, 本文的算法运行时间是指载入测试集并进行任务分配阶段的时间. 图 8 和图 9 展示了不同数据集下各算法运行时间的变化情况. 图 8(a)和图 9(a)显示了算法运行时间随候选者人数的变化, 整体看来 GSMS 算法的运行时间增长得最快, 而 g-MUS 增长得最慢, 这是因为 GSMS 在博弈过程中会消耗大量时间, 并且候选人数与博弈时迭代的次数成正比. 而 g-MUS 已经预测了候选者的兴趣点, 因此在此条件下进行的任务分配时间随人数的增加变化不大. TR-UMCR 算法则增长速度适中, 任务分配速度略优于改进前的 ListRank-MF 算法, 且一直优于基线方法. 图 8(b)和图 9(b)显示, 算法运行时间随任务数量变化的增幅相对较小, 这是因为 4 个方法都是从候

者角度进行分析并展开任务分配的, 故而参与者越多复杂度越高, 运行时间变化越大. 同样, GSMS 增幅最大, TR-UMCR 算法与 g-MUS 增幅相似且较小.




(a)




(b)

图 8 Gowalla 数据集:算法运行时间与候选者和任务数的关系比较

激励效果比较基于每个感知用户推荐列表中命中的任务:一方面体现为感知候选者的参与度, 即在对相同数量的感知任务进行分配时, 参与感知任务的总人数; 另一方面体现为感知参与者的移动成本, 即每个任务之间距离累加所得到的总移动距离, 用户参与度越高, 移动距离越小, 则对感知用户的激励效果越好. 图 10 展示了参与人数随候选者变化的情况, 可以看到同等情况下, TR-UMCR 算法分配过程中的参与者积极性明显比其他方法更高, 参与率在 97% 左右, 基线方法的参与率均在 95% 以下. 图 11 显示了用户的平均移动距离随候选者数量的变化, 3 种方法都有上升趋势, 其中 GSMS 增长得最快, TR-UMCR 增长得最慢. 这是因为 TR-UMCR 算法之中有对参与者位置偏好的分析, 并将此分析结果作为一项指标融入到了损失函数中, 所以推荐的任务是符合候选者的移动特征的.



(a)



(b)

图9 交互数据集:算法运行时间与候选者和任务数的关系比较




图10 参与者数量与候选者关系比较

综上所述,本文方法分配准确率高并且分配速度快,与改进前的ListRank-MF算法相比具有明显的优势.与其他基线方法相比,本文方法分配准确率明显高于g-MUS算法,GSMS算法虽然分配准确率尚可,但是计算开销过大导致运行时间过长.通过TR-UMCR算法进行的任务分配不仅减少了用户的移动成本,而且有效地提高了用户的参与积极性.本文方法总体性能良好,优于基线方法.




图11 平均移动距离与候选者关系比较

## 6 结论

本文提出了一种基于混合用户模型与列表级排序学习算法相结合的协同排序任务推荐方法TR-UMCR.该方法充分分析了用户意愿以及用户间的关系,在此基础上构建了混合用户模型,并结合任务分解方法、任务列表排序方法,实现了资源的有效利用以及任务的合理分配.在移动群智感知系统中,利用TR-UMCR方法进行任务分配,提高了任务分配准确率的同时,也提高了用户的参与积极性.本文方法是基于离线用户制定的,现有的用户池是确定的,但是对于复杂且不确定的用户临时加入的情况没有考虑到,对于这种动态分配情况有待深入研究.在下一步的工作中,会针对如何对在线用户进行有效的任务分配做出改进,使其能够适应更加复杂多变的环境.

## 参考文献

- [1] Guo B, Wang Z, Yu Z W, et al. Mobile crowd sensing and computing: The review of an emerging human-powered sensing paradigm[J]. ACM Computing Surveys, 2015, 48(1): 1 - 31.
- [2] Shu L, Chen Y F, Huo Z Q, et al. When mobile crowd sensing meets traditional industry[J]. IEEE Access, 2017, 5: 15300 - 15307.
- [3] 俞东进, 陈聪, 吴建华, 等. 基于隐式反馈数据的个性化游戏推荐[J]. 电子学报, 2018, 46(11): 2626 - 2632.  
Yu D J, Chen C, Wu J H, et al. Personalized game recommendation based on implicit feedback[J]. Acta Electronica Sinica, 2018, 46(11): 2626 - 2632. (in Chinese)
- [4] Xiong H Y, Zhang D Q, Chen G L, et al. iCrowd: Near-optimal task allocation for piggyback crowdsensing[J]. IEEE Transactions on Mobile Computing, 2016, 15(8): 2010 - 2022.
- [5] Wang J T, Wang F, Wang Y S, et al. Social-network-assist-

- ed worker recruitment in mobile crowd sensing[J]. IEEE Transactions on Mobile Computing, 2019, 18(7): 1661 – 1673.
- [6] Liu Y, Guo B, Wang Y, et al. TaskMe: multi-task allocation in mobile crowd sensing[A]. Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing[C]. New York, NY, USA: ACM, 2016. 403 – 414.
- [7] Wang L, Yu Z W, Zhang D Q, et al. Heterogeneous multi-task assignment in mobile crowdsensing using spatiotemporal correlation[J]. IEEE Transactions on Mobile Computing, 2019, 18(1): 84 – 97.
- [8] 安健, 彭振龙, 桂小林, 等. 群智感知中基于公交系统的任务分发机制研究[J]. 计算机学报, 2019, 42(2): 65 – 78. An J, Peng Z L, Gui X L, et al. Research on task distribution mechanism based on public transit system in crowd sensing[J]. Chinese Journal of Computers, 2019, 42(2): 65 – 78. (in Chinese)
- [9] Yang Y J, Liu W B, Wang E, et al. A prediction-based user selection framework for heterogeneous mobile CrowdSensing[J]. IEEE Transactions on Mobile Computing, 2019, 18(11): 2460 – 2473.
- [10] Wang E, Yang Y J, Wu J, et al. An efficient prediction-based user recruitment for mobile crowdsensing[J]. IEEE Transactions on Mobile Computing, 2018, 17(1): 16 – 28.
- [11] 景瑶, 郭斌, 陈荟慧, 等. CrowdTracker: 一种基于移动群智感知的目标跟踪方法[J]. 计算机研究与发展, 2019, 56(2): 328 – 337. Jing Y, Guo B, Chen H H, et al. CrowdTracker: object tracking using mobile crowd sensing[J]. Journal of Computer Research and Development, 2019, 56(2): 328 – 337. (in Chinese)
- [12] Li H S, Li T, Wang Y. Dynamic participant recruitment of mobile crowd sensing for heterogeneous sensing tasks [A]. 2015 IEEE 12th International Conference on Mobile Ad Hoc and Sensor Systems[C]. Dallas, TX, USA: IEEE, 2015. 136 – 144.
- [13] Pournajaf L, Xiong L, Sunderam V. Dynamic data driven crowd sensing task assignment[J]. Procedia Computer Science, 2014, 29: 1314 – 1323.
- [14] Wang J T, Wang F, Wang Y S, et al. Allocating heterogeneous tasks in participatory sensing with diverse participant-side factors[J]. IEEE Transactions on Mobile Computing, 2019, 18(9): 1979 – 1991.
- [15] Abououf M, Singh S, Otrok H, et al. Gale-shapley matching game selection—A framework for user satisfaction[J]. IEEE Access, 2019, 7: 3694 – 3703.
- [16] Yuen M C, King I, Leung K S. TaskRec: A task recommendation framework in crowdsourcing systems[J]. Neural Processing Letters, 2015, 41(2): 223 – 238.
- [17] 丁宇新, 燕泽权, 冯威, 等. 基于有监督主题模型的排序学习算法[J]. 电子学报, 2015, 43(2): 333 – 337. Ding Y X, Yan Z Q, Feng W, et al. Rank learning based on supervised topic model[J]. Acta Electronica Sinica, 2015, 43(2): 333 – 337. (in Chinese)
- [18] 任开旭, 王玉龙, 刘同存, 等. 融合多维语义表示的概率矩阵分解模型[J]. 电子学报, 2019, 47(9): 1848 – 1854. Ren K X, Wang Y L, Liu T C, et al. A probabilistic matrix factorization model based on multidimensional semantic representation learning[J]. Acta Electronica Sinica, 2019, 47(9): 1848 – 1854. (in Chinese)
- [19] Shi Y, Larson M, Hanjalic A. List-wise learning to rank with matrix factorization for collaborative filtering[A]. Proceedings of the fourth ACM conference on Recommender systems - RecSys '10[C]. New York, USA: ACM Press, 2010. 269 – 272.
- [20] Cho E, Myers S A, Leskovec J. Friendship and mobility: User movement in location-based social networks[A]. Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '11[C]. New York, USA: ACM Press, 2011. 1082 – 1090.
- [21] 陈家银. 猪八戒众包平台数据分析与众包模式设计[D]. 大连: 大连理工大学, 2016. Chen J Y. Zhubajie crowdsourcing platform data analysis and crowdsourcing model design[D]. Dalian, China: Dalian University of Technology, 2016. (in Chinese)

#### 作者简介



王 健 女, 1979年6月出生, 黑龙江哈尔滨人. 毕业于哈尔滨工程大学, 获得博士学位. 现为哈尔滨理工大学教授、博士生导师, 主要从事未来网络与认知网络、群智感知、可信计算等方面的研究工作.

E-mail: wangjianlydia@163.com



刘嘉欣 女, 1996年9月出生, 黑龙江哈尔滨人. 现为哈尔滨理工大学计算机科学与技术学院硕士研究生, 主要从事群智感知、云计算与物联网安全等方面的研究工作.