

## 结合聚类与 CMAB 的群智感知车联网任务分配方法

冯心欣, 郭丹颖, 柳泽烽, 郑海峰

(福州大学物理与信息工程学院, 福建 福州 350108)

**摘要:** 基于车联网 (IoV, Internet of vehicles) 用户的群智感知网络具有节点覆盖广泛、数据全面及时等优点。该技术实现的一大难点在于, 如何通过充分挖掘和利用车联网用户的信息 (如用户地理位置等) 来选择合适的感知任务参与者, 以合理地进行任务分配, 进而提高感知任务的完成质量和任务发布者收益。为此提出了一种结合车辆用户轨迹特征与组合多臂赌博机 (CMAB, combinatorial multi-armed bandits) 算法的群智感知用户任务分配机制。首先, 基于用户历史行车轨迹的相似程度, 将用户聚类。然后, 利用 CMAB 模型, 将轨迹聚类信息作为用户任务分配的依据, 求解最佳工作者组合。最后, 利用真实出租车轨迹数据集对上述算法进行了验证。实验结果表明, 考虑轨迹特征信息的任务分配算法具有更高的准确率, 并能使任务发布者获得高收益。同时, 所选出的工作者集合有相近的行车轨迹, 对于同一地点的任务具有高的完成质量, 能有效提高感知数据质量和任务发布者收益, 适用于实际应用场景。

**关键词:** 群智感知; 车联网; 组合多臂赌博机模型; 轨迹聚类; 任务分配

**中图分类号:** TP391

**文献标识码:** A

**doi:** 10.11959/j.issn.2096-3750.2021.00224

## Task allocation in IoV-based crowdsensing combing clustering and CMAB

FENG Xinxin, GUO Danying, LIU Zefeng, ZHENG Haifeng

College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China

**Abstract:** The crowdsensing network based on Internet of vehicles (IoV) users has the advantages of extensive node coverage, complete and timely data. A major difficulty in the realization of this technology lies in how to fully mine and use the information of connected vehicular users (such as the user's geographic location, etc.) to select appropriate perception task participants, so as to carry out reasonable task assignments, thereby improving the completion quality of perception tasks and task publisher's benefits. To solve the above problems, a task allocation method combining the trajectory features and the combinatorial multi-armed bandits (CMAB) algorithm was proposed. Firstly, users were clustered based on the similarity of their historical driving trajectories. Then, the CMAB model was adopted so that the trajectory clustering information could be used as the basis for deciding the optimal worker combination. Finally, the proposed algorithm was verified using the real taxi-trajectory dataset. The experimental results show that the task assignment algorithm considering the trajectory feature information has a higher accuracy and higher profit. At the same time, the selected workers have a high completion quality for tasks at the same location, and can effectively improve the quality of perceived data and the benefits of task publishers, which is suitable for practical application scenarios.

**Key words:** crowdsensing, Internet of vehicles, CMAB model, trajectory clustering, task allocation

收稿日期: 2020-11-17; 修回日期: 2021-02-26

通信作者: 郑海峰, zhenghf@fzu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61601126, No.61971139)

**Foundation Items:** The National Natural Science Foundation of China (No.61601126, No.61971139)

## 1 引言

随着嵌入式设备的更新和互联网覆盖范围的扩大, 智能城市<sup>[1]</sup>的社会感知活动已成为信息和通信领域的研究热点。群智感知技术代替了传统传感网络, 规避其缺陷, 使传感更实时、便捷和低成本<sup>[2-3]</sup>。在与群智感知相关的研究中, 任务分配是目前国内外学者研究的核心问题之一, 该方面的研究主要分为任务自主选择 and 任务协调分配两类<sup>[4-5]</sup>, 易存在参与感知任务的用户技能水平不高、感知数据质量差的问题。因此, 在任务分配环节引入合适的算法进行工作者技能水平筛选, 并根据筛选结果进行感知任务分配, 可以大大提高感知数据的质量。作为一种新型的动态随机控制模型, 具有强大的学习能力多臂赌博机 (MAB, multi-armed bandit) 是解决上述问题的方案之一<sup>[6]</sup>。但是, 经典的 MAB 框架中存在从某些臂观察到的信息被丢弃的问题, 导致效率降低。为解决上述问题, 进一步提出了 CMAB 框架, 以解决在随机环境中的组合在线学习问题<sup>[7]</sup>。

群智感知车联网 (IoV, Internet of vehicles) 系统, 是群智感知技术在车联网领域的一个典型应用。通过多领域技术协同工作, 利用车辆用户携带的移动终端设备, 完成交通数据收集等感知任务, 进而达到数据预测、监测车辆和交通状况等目的<sup>[8-9]</sup>。与传统群智感知网络相比, 群智感知车联网具有如下特点: (1) 其典型任务往往与地理位置紧密相关<sup>[10]</sup>, 比如进行特定位置交通拥堵状态预测、特定区域地图绘制等。(2) 车辆用户具有移动性和一定随机性, 故任务分配者通常无法提前获得用户相关的先验知识, 如用户类型、用户能力、用户忠诚度等, 导致传统任务分配方法失效。因此, 在 IoV 系统中进行任务分配, 需要兼顾车辆用户的地理位置以及任务要求的地点、完成时间等多方面的因素, 并设法深入挖掘用户信息进行感知用户筛选。利用 IoV 中的海量轨迹数据挖掘车辆行驶的潜在规律, 如对具有相似行车轨迹的用户进行聚类, 并将其结果应用于用户筛选中, 可以在保证感知精度的同时, 大大降低感知成本。

本文提出了一种结合车辆轨迹特征与 CMAB 算法的群智感知用户任务分配机制, 通过挖掘群智感知车联网用户的历史轨迹信息, 将具有相同或相似轨迹的用户聚集在同一个簇类中, 并基于此轨迹

特征结合 CMAB 算法设计任务分配机制, 以达到提高感知数据质量和任务发布者收益的目的。

## 2 相关工作

合理的任务分配算法是提高群智感知质量的关键, 基于此, 许多学者做过相应研究工作。Zhou 等<sup>[11]</sup>提出了一种基于契约的激励机制, 以此来激励车辆共享资源, 并提出了基于价格的稳定的匹配算法来解决任务分配问题。Xiang 等<sup>[12]</sup>提出了一种基于用户竞价依赖性的平台用户激励机制, 用于任务分配中并通过平台和用户的交互来实现两者的双赢局面。由于现在众包任务分配多是考虑权衡平台和最小化用户之间的成本为目标而忽略了对于稳定性和满意度的考量, Xing 等<sup>[13]</sup>提出了一种基于拍卖的兼顾稳定性且用户满意度的智能多属性众包任务分配算法。但是上述算法没有考虑到在用户技能水平未知时, 如何进行有效的任务分配。而具有概率触发手臂 (PTA, probabilistically triggered arm) 的 CMAB 算法可以实现在未知工作者技能水平的情况下提取用户特征。Yang 等<sup>[14]</sup>针对已知场景提出了一种基于互信息的标准来表征用户的信息量, 采用多舍入算法求解该场景的用户选择问题, 针对未知场景, 将基于随机假设问题建模为预算多臂赌博机问题, 并提出了一种具有理论证明的后悔保证的算法求解该问题。Yang 等<sup>[15]</sup>为了解决 MCS 中的平台效益最大化时需考虑到的固定预算和时间联合约束问题, 建立了一个带有预算和时间限制的组合多臂赌博机模型, 并提出了一种有效的基于上置信界 (UCB, upper confidence bounds) 的用户选择算法, 最终证明该算法可以实现低后悔。Gao 等<sup>[16]</sup>考虑在异构 MCS 下, 将未知的工作者招募过程建模为一个新的 CMAB 问题, 且在该 CMAB 模型中包含一个预算受限的最大加权覆盖问题, 并在此基础上提出了一种基于 UCB 的扩展工作者招募算法, 同时推导了该算法的最差后悔值界限。

在任务分配阶段初始, 针对群智感知参与者众多带来的数据冗余和数据质量不高的问题, Wang 等<sup>[17]</sup>提出一种采用逻辑回归模型的参与者评估方案。Sun 等<sup>[18]</sup>提出约束和鞭策参与者行为的用户信誉模型, 根据用户历史的行为更新用户当前的信誉值。Yang<sup>[19]</sup>等提出了一种考虑任务内部依赖性的分配方法, 以解决在考虑利用用户可靠性来提高用户数据的准确性的同时由被忽略的子任务逻辑依赖

引起的问题。但是上述工作没有考虑到利用历史行为中的相似性,仅采用大量的数据资源来评估用户技能水平,实现复杂度较高。而基于海量的车联网轨迹数据,可以通过多种方法挖掘出车辆行驶的潜在相似规律,并将其应用于用户筛选中,其方法之一是轨迹聚类。经典轨迹聚类通常基于距离或密度<sup>[20]</sup>以及基于轨迹数据的相似性度量<sup>[21]</sup>,例如动态时间扭曲,实际序列上的编辑距离和最长公共子序列等来实现。Lee 等<sup>[22]</sup>提出了先将轨迹切成多个子轨迹,然后基于密度对子轨迹进行聚类的框架。Tang 等<sup>[23]</sup>提出了一种旅行行为聚类算法,该算法将采样与基于密度的聚类相结合,以处理轨迹数据中的噪声。Cheng 等<sup>[24]</sup>提出了一种基于时空模式的轨迹数据聚类算法,可用于预测未来的运动轨迹。

故针对 IoV 系统中缺乏用户先验知识的群智感知任务分配问题,本文提出了一种结合用户轨迹特征与 CMAB 理论的任务分配机制,实现提高感知数据质量和任务发布者收益的目的。

### 3 轨迹聚类特征的构建

本节简要概述轨迹聚类的 3 个阶段,其中所涉及的方法主要参考文献[25]。

在第 1 阶段中,给定道路网络,将覆盖整个道路网络的最小边界矩形划分为一系列网格单元。将包含车辆开始位置、行程位置和目标位置的轨迹投射到网格化后的道路网络中,并将其表示为覆盖其位置的时间有序网格单元序列。基于网格序列的距离函数计算不同轨迹间的距离。

在第 2 阶段中,通过轨迹映射算法 TrajMap<sup>[25]</sup>将每个轨迹转换为欧几里德空间中的  $d$  维点。将每对轨迹之间的网格序列距离转换成欧几里德空间中的每对点之间的距离。

在第 3 阶段中,在  $d$  维欧几里德空间中对轨迹映射的坐标点进行  $K$ -means 聚类。通过使用聚类平方和 (WCSS, within cluster sum of squares)<sup>[25]</sup>来判别聚类质量。WCSS 值越小则聚类质量越好。该聚类方法使具有相似程度高的历史行车轨迹的用户聚集在同一个类别中。值得注意的是,本文选择  $K$ -means 聚类方法是考虑其简单性和效率性,在仿真部分给出了一种最佳初始  $k$  值的确定方法。实际上,  $K$ -means 聚类方法不是轨迹聚类的唯一选择,例如对于自由移动轨迹路线可以采用 TraClus

聚类<sup>[22]</sup>;对于不确定的轨迹路线可以采用模糊  $c$  均值聚类算法进行聚类<sup>[26]</sup>等,可基于实际场景的需求进行灵活选择。

显然,在群智感知车联网系统中,同一类别中的用户在完成某些感知任务,如与地理位置相关的道路车流量和车辆速度数据采集、空气质量检测时,具有相似的能力。基于以上假设,本文方法将用户聚类的结果作为感知任务的工作者选择策略参考的特征之一。

## 4 结合轨迹特征的任务分配

### 4.1 相关概述

#### 4.1.1 组合多臂赌博机

在 CMAB 的框架中,假设有一组共  $m$  只的基臂,它们的结果遵循某些未知的联合分布。超级臂  $S$  是这组基臂的子集。在每一轮尝试中,推动一个超级臂即推动该超级臂包含的所有基臂。该轮尝试的收益由所有触发的超级臂的结果决定,其被观察为对在线学习算法的反馈。CMAB 算法需要使用过去几轮中的这些反馈信息来决定下一轮中的超级臂。学习算法结合实例问题的信息计算最优或近似最优的超级臂。

#### 4.1.2 常用策略

后悔值是衡量多臂收益值的标准之一<sup>[27]</sup>,代表的是最优策略对应的总收益和所执行策略的长期累积收益之间的差值。某个策略的后悔值越小,则越趋近于最优策略。常用的策略有如下 3 种。

- Random 策略采用随机选择的方式,每个手臂获得相同的被选中概率。

- $\epsilon$ -Greedy 策略<sup>[27]</sup>是一种贪婪策略,  $\epsilon$  值代表执行“探索”的概率。在选择手臂的过程中,以  $\epsilon$  的概率从所有手臂中随机选择一个进行尝试,执行“探索”操作,以  $1-\epsilon$  的概率选择目前收益最高的手臂执行“开发”操作。通过值  $\epsilon$  的设定在“开发”和“探索”之间实现权衡以最大化累积收益。

- 上置信界策略<sup>[27]</sup>在选择手臂时,除了考虑该臂的期望收益外,还考虑了该期望收益的置信度。在 CMAB 框架下,定义每个手臂的 UCB 值为

$$UCB_{i,t} = \bar{\mu}_{i,t} + \sqrt{\frac{3 \ln t}{2n_{i,t}}} \quad (1)$$

其中,  $t$  为摇臂轮数,  $n_{i,t}$  为手臂  $i$  到  $t$  轮时被摇的次

数,  $\bar{\mu}_{i,t}$  为手臂  $i$  到  $t$  轮为止的期望收益,  $\sqrt{\frac{3\ln t}{2n_{i,t}}}$  体现  $\bar{\mu}_{i,t}$  的不确定度。式(1)代表  $\bar{\mu}_{i,t}$  的置信区间上限。因此, 按照式(1)选择手臂时, 意味着倾向于选择收益大且被尝试了很多次置信度高的手臂 (体现了“开发”的过程), 或选择收益不够大但被尝试次数少不确定度高的手臂 (体现了“探索”的过程)。

#### 4.2 系统模型

假设有数据采集项目分布于某给定道路网络中, 参照第3节第1阶段的处理方式, 将道路网络划分为一系列单元格并标记为  $\mathcal{L} = \{1, 2, 3, \dots, L\}$ 。假设共有  $K$  项采集任务, 记为  $\mathcal{C} = \{1, \dots, K\}$ , 位于不同的单元格, 每个任务有质量要求  $Q_k$ 。任务  $k$  的位置用  $l_k$  表示, 其中  $l_k \in \mathcal{L}$ 。假设共有  $M$  位工作者愿意参与到数据采集项目中, 记为  $\mathcal{M} = \{1, \dots, M\}$ , 假设整个任务采集过程持续  $T$  个时隙。本文任务分配问题的目标是, 如何在尽可能满足任务质量要求的条件下, 选择工作者以使得任务发布者获得最大的收益。

将  $M$  位工作者和  $K$  项任务看成共  $MK$  只手臂, 则上述问题可建模为一个 CMAB 问题。CMAB 问题包括  $MK$  只基臂和与之相关联的一组随机变量  $X_{i,t}^k \in [0, 1]$ , 其中  $1 \leq i \leq M, 1 \leq t \leq T, 1 \leq k \leq K$ 。变量  $X_{i,t}^k$  表示第  $t$  次试验中推动第  $i$  只基臂执行第  $k$  个任务获得的随机结果。设  $X_{i,t}^k$  是独立的且服从期望为  $u_i^k$  的未知分布。用向量  $\boldsymbol{\mu} = (u_1^1, u_1^2, \dots, u_M^K)$  表示所有基臂的期望。定义  $\mathcal{S} \subseteq 2^{[MK]}$  为所有基臂可能的组合的集合, 定义  $S_t \in \mathcal{S}$  为一个超级臂, 即第  $t$  次实验选择的一组工作者组合。假设任务分配方案是  $S_T$ , 其中  $S_T^k$  是任务  $k$  最终所分配工作者的集合。假设用户在不同的感知任务中的技能水平是有差别的, 该技能差别体现在用户执行不同任务时的随机结果中。对于第  $k$  项任务, 工作者  $i$  在该类任务上的技能水平  $p_i^k(t)$  可通过其以往对该任务的历史完成率来定义, 如

$$p_i^k(t) = \frac{\sum_t c_{i,k}^t}{\sum_t c_{i,k}^t + \sum_t E_{i,k}^t + \varepsilon} \quad (2)$$

其中,  $c_{i,k}^t = 1$  表示用户  $i$  在第  $t$  次实验中给出任务  $k$  的感知结果达到任务要求,  $E_{i,k}^t = 1$  表示用户  $i$  在第  $t$  次实验中给出任务  $k$  的感知结果未达到任务要

求。本文为式子加入调和因子  $\varepsilon$ , 以避免在实验次数较少时工作者的技能水平估计误差过大。定义  $n_{i,t}^k$  为用户  $i$  到  $t$  轮时执行任务  $k$  的总次数, 定义用户  $i$  到  $t$  轮时在执行任务  $k$  时的总期望收益为

$$\bar{\mu}_{i,t}^k = \mathbb{E} \left[ \sum_t X_{i,t}^k \right] \quad (3)$$

任务分配问题可表示为

$$\max_{S_t \in \mathcal{S}} \mathbb{E}_{S_t} \left[ \sum_{t=1}^T r_{\boldsymbol{\mu}}(S_t) \right] \quad (4)$$

在式(4)中, 目标函数为任务发布者获得的总收益。 $r_{\boldsymbol{\mu}}(S_t)$  定义如下

$$r_{\boldsymbol{\mu}}(S_t) = \mathbb{E} \left[ \sum_{i \in S_t, k \in \mathcal{C}} X_{i,t}^k \right] \quad (5)$$

式(5)代表第  $t$  次实验所选择工作者组合的期望收益。

#### 4.3 结合轨迹特征的任务分配

每个工作人员对于每种类型的任务都具有未知的技能水平, 即完成任务的收益未知, 本文需要利用 CMAB 策略多次分配任务给用户, 并将完成的感知质量当作反馈结果, 以形成对用户技能水平的估计, 然后根据探索后的用户技能水平, 从中选择最佳工作者组合, 使得任务发布者的总收益达到最大。

在任务分配算法的初始阶段, 所有用户的技能水平都是未知的, 因此, 传统算法需要先选择每个用户进行感知任务才能根据反馈结果估计其技能水平, 这对于成本的消耗是相当巨大的。本节提出一种结合轨迹特征的技能水平估计方法, 目的是在尽可能减少感知任务实施次数的同时, 能较为准确地初步估计出所有用户的技能水平。

本文算法的主要思想是根据一个群体里的某些用户对于感知任务的真实反馈初步更新这一群体里所有用户对这类型感知任务的个人技能水平。将针对相同任务具有相同技能水平的用户聚类为群集用户, 并假设他们具有类似的任务反馈结果。

在第3节轨迹特征构建部分, 根据车联网用户的历史行车轨迹, 将所有工作者聚集在不同群集中, 同一群集里的工作者具有相同或相似程度高的历史轨迹, 其对于同一个地点的感知任务将具有较高的完成能力即技能水平。由此, 在初步估计工作

者的技能水平时，将他们的实验反馈结果累积计算其共同的技能水平，以达到用较少的实验次数估计出所有工作者的技能水平的目的。具体计算方式如下

$$p_i^k(t) = \frac{\sum_{h \in C_p} \sum_t c_{h,k}^t}{\sum_{h \in C_p} \sum_t c_{h,k}^t + \sum_{h \in C_p} \sum_t E_{h,k}^t} \quad (6)$$

其中， $C_p$  表示工作者  $i$  所属簇类， $c_{h,k}^t = 1$  表示第  $t$  次实验工作者  $h$  给出任务  $k$  的感知结果达到任务质量要求， $E_{h,k}^t = 1$  表示第  $t$  次实验工作者  $h$  给出任务  $k$  的感知结果未达到任务质量要求。

具体算法过程如下。

首先，前  $T_1$  轮前初步估计用户技能水平。观察这一轮实验的所有工作者在这次被分配感知任务的真实反馈。对于工作者  $i$  来说，通过式(6)计算其所属簇类  $C_p$  的所有工作者的平均技能水平，这个参数将直接作为工作者  $i$  的技能水平  $p_i^k$  参与到下一次的选择决策中。

然后，在  $T_1$  轮后观察工作者的真实反馈，更新工作者自己的技能水平（更新个人的，对应类簇里其他的用户不更新），并基于更新后的工作者技能水平来更新工作者的总期望收益。

具体伪代码如算法 1 所示。

**算法 1** 结合轨迹特征与 CMAB 模型的群智感知任务分配

**输入** 用户集合  $\mathcal{M} = \{1, \dots, M\}$ ，用户聚类群集  $\mathcal{P} = \{1, \dots, C_p\}$ ，任务集合  $\mathcal{C} = \{1, \dots, K\}$

**输出** 最佳工作者组合  $S$

预设  $p_i^k = 0.5$ ， $\forall i \in \mathcal{M}$ ， $\forall k \in \mathcal{C}$ ，设  $\bar{\mu}_{i,t}^k = 0$ ， $n_{i,1}^k = 0$

for  $t = 1 : T_1$  do

    根据 3.1.2 节所述策略选择一组工作者集合  $S_t$

$\forall i \in S_t$ ，由式 (6) 更新  $p_i^k(t)$ ，若  $i \in C_p \forall h \in C_p$ ， $p_h^k(t) \leftarrow p_i^k(t)$ ，更新  $n_{i,t}^k$ ，由式(3)更新  $\bar{\mu}_{i,t}^k$

$t \leftarrow t + 1$

end for

for  $t = T_1 + 1 : T$

    根据 3.1.2 节所述策略选择一组工作者集合  $S_t$

$\forall i \in S_t$ ，由式(2)更新  $p_i^k(t)$  和  $n_{i,t}^k$ ，由式(3)更新  $\bar{\mu}_{i,t}^k$

$t \leftarrow t + 1$

end for

return  $S$

## 5 实验

### 5.1 实验配置

本文实验采用滴滴出行公司提供的真实出租车轨迹数据，原始数据集主要包含整个成都市在 2016 年 11 月的所有出租车轨迹数据。原始数据集中的轨迹数据含有加密处理后的司机 ID、订单 ID、时间戳、经度和纬度这 5 项数据。为了提供数据合理利用率以及保证后期数据分析的正确性，需要在得到数据的基础上对数据进行预处理，如选取实验数据区域以及剔除重复数据和缺失数据。得到了经过数据预处理的出租车司机轨迹数据，需要用简单的数字 ID 代替复杂的司机 ID 以便实验，并且统计了总工作者人数  $M=496$ 。工作者数据示例如表 1 所示。

表 1 工作者数据示例

工作者 ID	时间	经度	纬度
1	2016/11/1 15:26:21	104.075 75	30.685 06
1	2016/11/1 15:26:27	104.076 06	30.685 60
2	2016/11/1 15:00:02	104.082 70	30.682 71
⋮	⋮	⋮	⋮
496	2016/11/1 15:09:49	104.081 65	30.680 27

选取实验数据区域过程如下：由于数据集过于庞大，因此需缩小数据涉及范围，故截取成都市某块区域内的所有出租车历史行车记录点，并从此区域选取用以设置感知任务的地点。该选定区域包含文殊院景点区域及附近城市道路，经纬度范围为 104.074 58°~104.084 60°E、30.675 64°~30.685 65°N。实验区域的地图如图 1 所示，感知地点为在地图里设置 50 m×50 m 的方块区域。

在如下的实验过程中采用准确率和后悔值对实测数据进行验证分析，其中准确率指的是每种策略最终所选择的用户实际完成任务的概率的均值，准确率越高则该策略的任务完成度越高；后悔值用来衡量每种策略完成任务的收益情况，若后悔值越小则该策略，越接近最优策略即该策略能最大化任务发布者的收益。

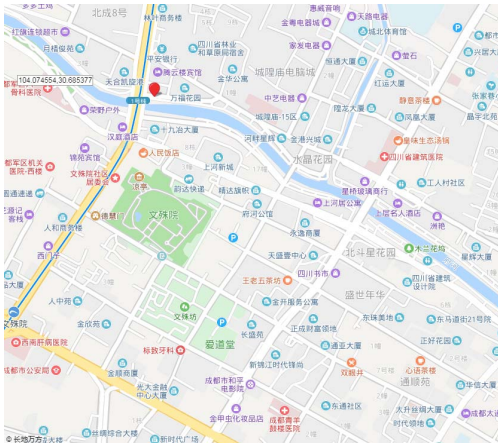


图 1 实验区域地图截取

本文将结合轨迹特征的任务分配使用 UCB 策略简称为 CUCB 策略，结合轨迹特征的任务分配使用 Random 策略简称为 CRandom 策略，结合轨迹特征的任务分配使用  $\epsilon$ -Greedy 策略简称为 CEGreedy 策略。为方便比较，在下述实验中将  $\epsilon$ -Greedy 策略称为 EGreedy 策略。

### 5.2 实验结果与分析

#### 5.2.1 构建轨迹特征的聚类 $k$ 值确定

在特征的构建部分中，在使用  $K$ -means 算法进行聚类时需要确定群集值。为了确定群集值，本文设计在聚类中心数目取值不同的情况下，实验并计算出对应的 WCSS 值。实验结果如图 2 所示。




图 2 不同取值  $k$  下的 WCSS 值

由图 2 可以看出，群集数为 12 时 WCSS 值取得最小，较小的 WCSS 值意味着更好的聚类质量。因此，下文的所有实验都是基于上述结果进行分析实验的。

#### 5.2.2 工作者技能水平服从伯努利分布实验

当交通数据采集任务要求只有工作者到达指

定目的地，工作者对于任务的完成情况只有两种结果（到达指定目的地和不能到达指定目的地），本节实验假设用户技能水平服从伯努利分布，即感知结果  $X_{i,t}^k$  以概率  $p_i^k(t)$  为 1，以概率  $1 - p_i^k(t)$  为 0。实验时所设置的技能水平对于任务分配系统来说默认为未知的。在实验中，本文设定单个任务即  $K = 1$ ，假设该任务要求选取的工作者总数量为 10 以达到所需的感知质量，最大迭代次数为 2 000， $K$ -means 算法群集数取 12。实验参数如表 2 所示。

表 2 实验参数

感知总 工人数/人	选取工人 总数量/人	最大迭代次数 ( maxIters )	聚类 群集数
496	10	2 000	12

图 3 显示了不同迭代次数下每种策略的后悔值的变化。从图 3 中可以看出，随着迭代次数的增加，CRandom 策略由于随机选择工作者，所选工作者和最优工作者有较大差异，故该策略的后悔值一直保持较高增长速度；CEGreedy 策略和 CUCB 策略的后悔值增长得越来越慢，CUCB 策略的后悔值最终会低于 CEGreedy 策略并趋于稳定。这是因为 CEGreedy 策略在每轮中会以  $1 - \epsilon$  概率来选出当下已知工作者中的最优的工作者以  $\epsilon$  概率去探索未知工作者。故在迭代次数较少时，该策略对于未知工作者的探索不足可能会错过当中最优的工作者，而当迭代次数越来越多时，未知工作者逐渐减少该策略从已知工作者中选出最优的工作者的概率增大。CUCB 策略在迭代次数较少时，由于所有工作者的置信度都很高也就是有很高的不确定性，故初期会对每个工作者都进行尝试选择，那么在这个过程中选中最优工作者的概率自然不高，后悔值就较高，而当迭代次数较多时，就可以选择所有尝试选择过的工作者中最优的，则此时后悔值就趋于稳定。说明本文采用 CUCB 策略和 CEGreedy 策略做感知任务的工作者分配可以渐近实现最优选择，在迭代次数较大时，CUCB 策略效果更好一些。

图 4 显示了不同迭代次数下每种策略的准确率的变化。从图 4 中可以看出，随着迭代次数的增加，CRandom 策略的准确率基本保持较低不变，CEGreedy 策略的准确率基本保持较高不变，CUCB 策略的准确率在迭代次数较低时并不高，但随着迭代次数的不断增加，准确率不断增加，保持在 0.80 左右，并高于 CEGreedy 策略。

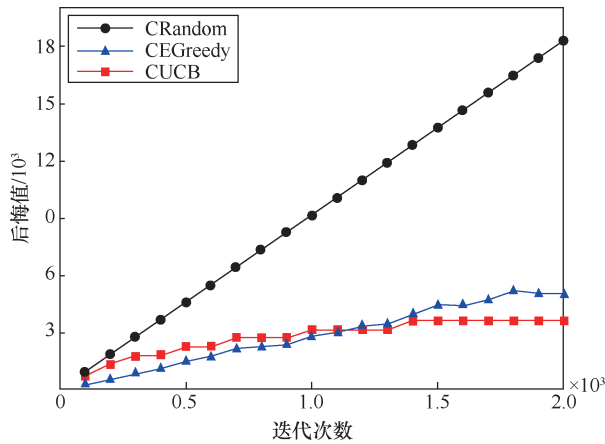


图 3 不同迭代次数下任务完成的后悔值




图 5 不同迭代次数下的运行时间对比

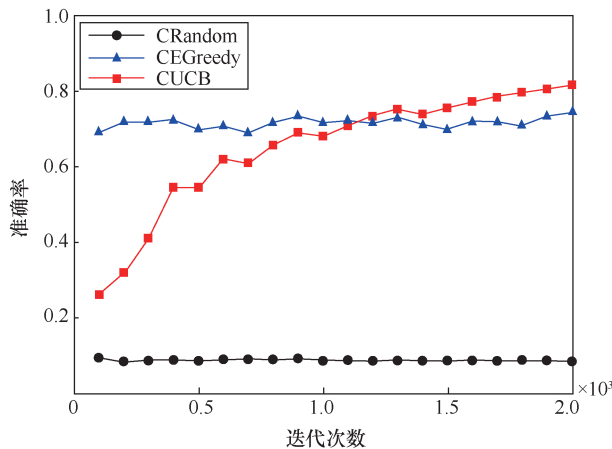


图 4 不同迭代次数下任务完成的准确率

由图 3 和图 4 可以看出，在工作者技能水平服从伯努利分布的实验下，CRandom 策略的实验结果较差，CUCB 策略在迭代次数足够多时，效果最好。故本文参照 CUCB 的性能，在迭代次数大于 1 200 次的情况下，后悔值趋于稳定准确率一直逐步上升，因此采用 2 000 次作为本实验的最大迭代次数。

图 5 显示了不同迭代次数下每种策略的运行时间的变化。从图中可以看出，随着迭代次数的增加，CUCB 策略和 CEGreedy 策略的运行时间较短，且增长速度缓慢；而 CRandom 策略的运行时间最长，且增长速度最快。这是因为相对于仅以  $\epsilon$  概率去探索未知技能水平的工作者的 CEGreedy 策略而言，CUCB 策略有助于系统以更快的速度累计工作者选择时的先验知识，帮助系统以较短的时间达到总能选出最优工作者的效果。CRandom 策略以随机概率来选择工作者，未累计先验知识，故随着迭代次数的增加，算法的整体运行时间也逐渐增大。

接着，本文研究了任务所选取工作者数量的变化对感知任务分配的后悔值的影响。令任务要求选取的工作者总数量在 1、6、11、...、46 之间变化，其他实验数据的默认设置为：感知总用户数量  $M=496$ ，最大迭代次数为 2 000。实验结果如图 6、图 7 所示。




图 6 任务选取的工作者数量在不同情况下任务完成的后悔值

图 6 为各策略的后悔值在感知任务选取的工作者数量不同下的变化曲线。在图 6 中可以发现，随着任务选取的工作者数量的增加，CUCB 策略的后悔值增长非常缓慢，几乎保持不变，这是因为产生了更多技能水平达到或接近最佳水平的工作者，如果将任务分配给这些工作者，那么总的后悔值就可能不会增加。而 CEGreedy 策略的后悔值变化趋势和 CUCB 策略是相似的，但总体表现值都大于 CUCB 策略的后悔值，这是因为 CEGreedy 策略总是选择已知技能水平的工作者，而对于未知技能水平的用户探索相对较少，易陷于局部最优解。而对于 CRandom 策略，后悔值是最大的，而且随着感知

任务选取的工作者数量的增加，后悔值的增长速度并没有变慢。

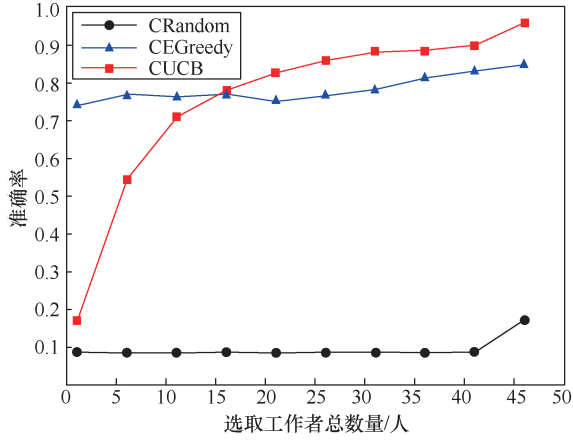


图 7 任务选取的工作者数量在不同情况下任务完成的准确率

图 7 为各策略的准确率在感知任务选择工作者数量不同下的变化曲线。从图 7 中可以明显看出，CRandom 策略的准确率保持在 0.1 之间基本不变，CEGreedy 策略的准确率值在 0.71 左右小幅度波动，而 CUCB 策略的准确率随着选择工作者数量的增加而增加，当工作者总数量大于 11 时，CUCB 策略的准确率超过 CEGreedy 的准确率并趋近于 0.95。

由图 6 和图 7 可以看出，在感知任务选择足够的工作者时，CUCB 策略的性能优于 CRandom 策略和 CEGreedy 策略。

接着，本文以 CUCB 策略为例研究在迭代 2 000 次时该策略下工作者选择的结果。实验结果见图 8，其中设定当第  $t$  轮工作时工作者  $j$  被选择时用黄点标识。则由图 8 可以看出，在迭代初期，CUCB 策略对于工作者的选择较为分散，但随着迭代次数的增加，所选择的工作者趋于稳定。在实验迭代到 2 000 次后，由图 8 可以看出，感知任务最终所选择的工作者集合为  $S_{2000} = \{25, 58, 208, 213, 264, 277, 307, 331, 384, 440\}$ ，这些用户的轨迹在地图上的展示如图 9 所示，用不同的颜色代表这些用户的行车轨迹，其中黑色箭头标注的为任务地点。

从图 9 可以看出，所选工作者的轨迹都会经过任务地点，故结合图 6 和图 7 的结果分析，可知所选工作者集合  $S_{2000}$  对于感知任务完成质量高，故该实验结果与倾向于选择技能水平高的工作者相符合。

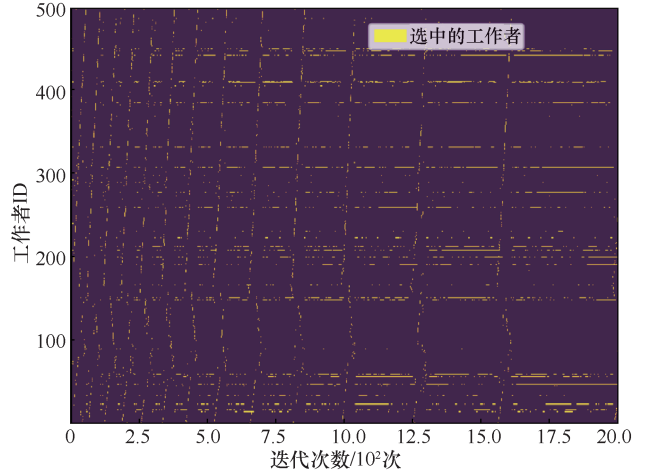


图 8 CUCB 策略下 2 000 次迭代工作者选择结果



图 9 所选工作者的轨迹

由图 8 和图 9 可知，本文提出的结合轨迹特征和 CMAB 模型的任务分配算法所选出的工作者集合具有相同或相似程度高的历史轨迹，对于同一地点的任务具有较高的完成质量，这也说明了本文所提出的策略适用于实际应用场景。

### 5.2.3 对比实验

考虑轨迹特征的任务分配与不考虑轨迹特征的任务分配策略进行对比实验。实验分别使用 UCB 策略和 EGreedy 策略下任务完成的后悔值对比，结果如图 10~图 12 所示。

图 10 为分别对比采用 UCB 策略和 CUCB 策略下的实验后悔值以及采用 EGreedy 策略和 CEGreedy 策略下的实验后悔值。首先在前组对比中可以看出，在迭代次数为 100 时，CUCB 策略的后悔值比 UCB 策略小了 1.7%；在迭代次数为 1 000 时，CUCB 策略的后悔值比 UCB 策略小了 22.7%；而后随着迭代次数的增加，两个值的差距越来越

大,但是 CUCB 策略逐渐趋于收敛,体现了轨迹聚类辅助的优势,速度更快、更早稳定,后悔值更小。

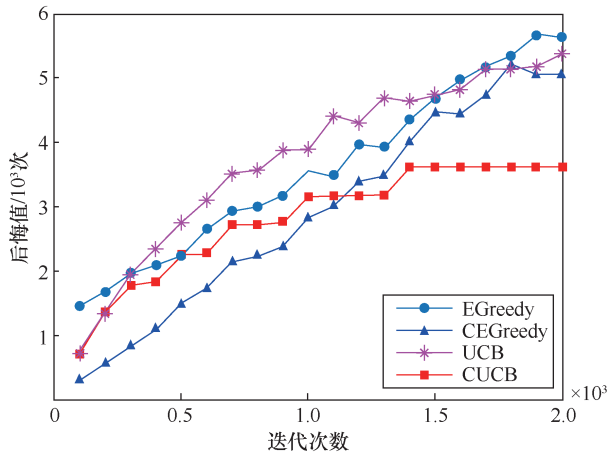


图 10 UCB 策略和 EGreedy 策略的实验后悔值对比

然后在后组对比中可以看出,在迭代次数为 200 时,CEGreedy 策略的后悔值比 EGreedy 策略小了 66.7%;而后其他迭代次数,两个值的差距在 5% 上下波动,体现了结合轨迹特征的优势,速度更快、更早稳定、后悔值更小。

图 11 为分别对比采用 UCB 策略和 CUCB 策略下的实验准确率以及采用 EGreedy 策略和 CEGreedy 策略下的实验准确率。首先在前组对比中可以看出,在迭代次数为 100 时,CUCB 策略的准确率比 UCB 策略高了 5.2%;在迭代次数为 200 时,CUCB 策略的准确率比 UCB 策略高了 22.5%,并且更早趋向于稳定,体现了轨迹聚类辅助的优势,速度更快、更早稳定、准确率更高。

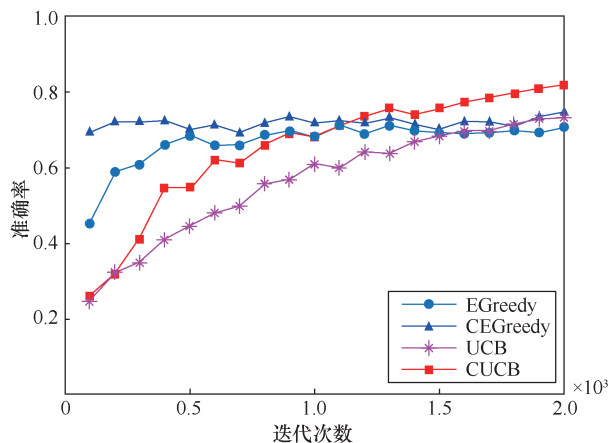


图 11 UCB 策略和 EGreedy 策略的实验准确率对比

在后组对比中可以看出,在迭代次数为 100 时,CEGreedy 策略的准确率比 EGreedy 策略高了

53%;在迭代次数为 200 时,CEGreedy 策略的准确率比 EGreedy 策略高了 22.2%,并且更早趋向于稳定,体现了轨迹聚类辅助的优势,速度更快、更早稳定、准确率更高。

图 12 为采用 EGreedy 策略和 UCB 策略下的运行时间对比。由于 CEGreedy 策略和 CUCB 策略结合了聚类算法,迭代初期的运行时间较长。但是随着迭代次数的增加,EGreedy 和 CEGreedy 以及 UCB 和 CUCB 两组策略的运行时间逐渐接近。如在迭代次数为 2000 时,CEGreedy 策略的运行时间和 EGreedy 策略相差仅为 6.4%。这说明聚类算法为工作者选择带来足够和有效的先验信息。因此,在迭代次数足够多时,考虑轨迹特征的任务分配策略相对于没有考虑轨迹特征的策略而言,在保证运行时间增长有限的前提下,有较明显的降低后悔值和提升准确率的效果。




图 12 UCB 策略和 EGreedy 策略的运行时间对比

由上述结果分析可知,本文方法优于没有考虑轨迹特征聚类的任务分配策略,对提高感知数据质量具有一定的价值。

### 6 结束语

本文针对群智感知车联网任务分配问题,考虑用户轨迹信息,提出了一种结合轨迹特征与 CMAB 模型的群智感知用户任务分配机制。并基于真实出租车轨迹数据集对该机制进行验证。由实验结果可知,结合轨迹特征和 CMAB 模型的任务分配算法所选出的工作者集合具有相同或相似程度高的历史轨迹,对于同一地点的任务具有较高的完成质量,适用于实际应用场景。仿真结果表明,考虑轨迹特征的任务分配策略相对于没有考虑轨迹特征

的任务分配策略其后悔值有所降低, 准确率有所提高, 并更早、更快地趋向于稳定, 从而实现提高感知数据质量以及任务发布者收益的目的。

但是本文研究的基于 CMAB 理论的群智感知任务分配算法仍然存在一定的改进空间, 下一步的研究工作是引入任务发布者预算等实际影响因素, 将其纳入数学模型进行最优工作者组合求解。同时, 考虑进一步降低算法的复杂度并将本文算法运用于其他场景中, 以提高其应用价值。

### 参考文献:

- [1] 李陈生. 基于城市交通的车载移动群体感知网络技术研究[D]. 北京: 北京邮电大学, 2019.  
LI C S. Research on vehicle mobile crowdsensing network technology based on urban public transportation[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [2] 刘媛妮, 李慧聪, 关鑫, 等. 移动群智感知激励机制研究综述[J]. 重庆邮电大学学报(自然科学版), 2018, 30(2): 147-158.  
LIU Y N, LI H C, GUAN X, et al. Review of incentive mechanism for mobile crowd sensing[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2018, 30(2): 147-158.
- [3] DASARI V S, KANTARCI B, POURYAZDANPANAH M, et al. Game theory in mobile crowdsensing: a comprehensive survey[J]. Sensors, 2020, 20(7): 1-23.
- [4] 方文凤, 周朝荣, 孙三山. 移动群智感知中任务分配的研究[J]. 计算机应用研究, 2018, 35(11): 3206-3212.  
FANG W F, ZHOU C R, SUN S S. Research on task assignment for mobile crowdsensing[J]. Application Research of Computers, 2018, 35(11): 3206-3212.
- [5] 黄涛. 移动群智感知网络中任务分配机制研究[D]. 重庆: 重庆大学, 2019.  
HUANG T. Research on task assignment mechanism in mobile crowdsensing network[D]. Chongqing: Chongqing University, 2019.
- [6] ROBBINS H. Some aspects of the sequential design of experiments[J]. Bulletin of the American Mathematical Society, 1952, 58(5): 527-536.
- [7] CHEN W, WANG Y J, YUAN Y, et al. Combinatorial multi-armed bandit and its extension to probabilistically triggered arms[J]. Journal of Machine Learning Research, 2016, 17(50): 1-33.
- [8] 徐晓雨. 车联网群智感知任务分发研究与实现[D]. 北京: 北京工业大学, 2018  
XU X Y. Research and implementation of task allocation for crowd sensing in Internet of vehicles[D]. Beijing: Beijing University of Technology, 2018
- [9] WAN J F, LIU J N, SHAO Z H, et al. Mobile crowdsensing for traffic prediction in internet of vehicles[J]. Sensors, 2016, 16(1): 88.
- [10] 严嘉赉. 基于群智感知的车联网节点优化方法与应用[D]. 南京: 南京邮电大学, 2019.  
YAN J Y. Optimization method and application of vehicle network node based on crowdsensing[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019.
- [11] ZHOU Z, LIU P, FENG J, et al. Computation resource allocation and task assignment optimization in vehicular fog computing: a contract-Matching approach[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 3113-3125.
- [12] XIANG C C, HE S N, SHIN K G, et al. Incentivizing platform-user interactions for crowdsensing[J]. IEEE Internet of Things Journal, 2020: 1-14.
- [13] XING Y P, WANG L M, LI Z Y, et al. Multi-attribute crowdsourcing task assignment with stability and satisfactory[J]. IEEE Access, 2019, 7: 133351-133361.
- [14] YANG S, WU F, TANG S J, et al. Selecting most informative contributors with unknown costs for budgeted crowdsensing[C]//2016 IEEE/ACM 24th International Symposium on Quality of Service (IWQoS). Beijing: IEEE Press, 2016: 1-6.
- [15] YANG S, QI X T, WU F, et al. Bandit user selection algorithm for budgeted and time-limited mobile crowdsensing[C]//GLOBECOM 2017-2017 IEEE Global Communications Conference. Singapore: IEEE Press, 2017: 1-6.
- [16] GAO G J, WU J, XIAO M J, et al. Combinatorial multi-armed bandit based unknown worker recruitment in heterogeneous crowdsensing[C]//Proceedings of the 39th IEEE International Conference on Computer Communications (INFOCOM 2020). Toronto: IEEE Press, 2020: 179-188.
- [17] 王涛春, 刘婷婷, 刘申, 等. 群智感知中的参与者信誉评估方案[J]. 计算机应用, 2018, 38(3): 753  
WANG T C, LIU T T, LIU S, et al. Participant reputation evaluation scheme in crowd sensing[J]. Journal of Computer Applications, 2018, 38(3): 753.
- [18] 孙鸿滨. 移动群智感知中基于数据质量的参与者优选方法[D]. 北京: 北京交通大学, 2019  
SUN H B. Quality-aware based participant selection for mobile crowd sensing[D]. Beijing: Beijing Jiaotong University, 2019
- [19] YANG C Y, YU Z W, LIU Y M, et al. Dynamic allocation for complex mobile crowdsourcing task with internal dependencies[C]//2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCCom/IOP/SCI). Leicester: IEEE Press, 2019: 818-825.
- [20] YUAN G, SUN P H, ZHAO J, et al. A review of moving object trajectory clustering algorithms[J]. Artificial Intelligence Review, 2017, 47(1): 123-144.
- [21] GAWDE G, PAWAR J. Similarity search of time series trajectories based on shape[C]//The ACM India Joint International Conference. New York: ACM Press, 2018: 340-343.
- [22] LEE J, HAN J, WHANG K. Trajectory clustering: a partition-and-group framework[C]//Proceedings of the ACM SIGMOD International Conference on Management of Data. New York: ACM Press, 2007: 593-604.
- [23] TANG W, PI D C, HE Y. A density-based clustering algorithm with sampling for travel behavior analysis[C]//Intelligent Data Engineering and Automated Learning- IDEAL 2016. Yangzhou: Springer Press, 2016: 231-239.

- [24] CHENG Z Y, JIANG L, LIU D S, et al. Density based spatio-temporal trajectory clustering algorithm[C]//IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium. Valencia: IEEE Press, 2018: 3358-3361.
- [25] HAN B, LIU L, OMIECINSKI E. A systematic approach to clustering whole trajectories of mobile objects in road networks[J]. IEEE Transactions on Knowledge and Data Engineering, 2017, 29(5): 936-949.
- [26] PELEKIS N, KOPANAKIS I, KOSTIFAKOS E, et al. Clustering trajectories of moving objects in an uncertain world[C]//2009 9th IEEE International Conference on Data Mining. Miami: IEEE Press, 2009: 417-427.
- [27] KROSE B. Learning from delayed reward[J]. Robotics and Autonomous Systems, 1995, 15(4): 233-235.
- [28] AUER P, CESA-BIANCHI N, FISCHER P. Finite-time analysis of the multiarmed bandit problem[J]. Machine Learning, 2002, 47(2): 235-256.



郭丹颖（1995-），女，福州大学硕士生，主要研究方向为群智感知网络激励机制设计。



柳泽烽（1993-），男，福州大学硕士生，主要研究方向为群智感知中的任务分配和数据处理。

#### [作者简介]



冯心欣（1983-），女，博士，福州大学副教授、硕士生导师，主要研究方向为移动群智感知网络中的激励机制设计，数据分析算法设计和系统构建。



郑海峰（1978-），男，博士，福州大学教授、博士生导师，主要研究方向为压缩感知、矩阵/张量填充、车联网、机器学习、边缘计算等理论及其在群智感知网络中的应用。