

移动群智感知网络中信息量最大化的用户选择方法研究

杨 朔 吴 帆 陈贵海

(上海交通大学计算机科学与工程系 上海 200240)

摘 要 移动群智感知网络已经成为一种新型的感知模式,被广泛应用在环境数据收集等多种不同场景.限制群智感知系统效能的一个关键问题在于:如何在一定预算范围内选取最合适的用户来进行感知任务,从而最大化收集到数据的信息量.这其中的关键挑战包括:(1)如何定义量化评价指标衡量数据的信息量,(2)如何在无先验知识的情况下有效地学习选择每个用户的成本,(3)如何设计有效的用户选择算法,最大程度地降低算法的累计遗憾.在本文中,我们采用高斯过程建模空间环境,并且提出一个基于互信息的信息量衡量指标.为了解决第二、第三个挑战,我们提出有预算限制的多臂老虎机用户选择问题模型,并为静态和动态场景分别设计了理论可证的低累计遗憾的多轮用户选择算法.我们的理论分析和仿真实验均证实我们提出的算法能够在预算限制情况下有效地选择最有信息量的用户,与基准方法相比提升约20%.

关键词 移动群智感知;用户选择;多臂老虎机问题;预算限制;空间相关性

中图法分类号 TP393 **DOI号** 10.11897/SP.J.1016.2020.00409

On Designing Most Informative User Selection Methods for Mobile Crowdsensing

YANG Shuo WU Fan CHEN Gui-Hai

(Department of Computer Science and Engineering, Shanghai Jiao Tong University, Shanghai 200240)

Abstract With the rapid development of mobile devices and wireless technology, mobile crowdsensing has become a novel and promising to sense paradigm. In mobile crowdsensing, there are three major components: service requesters, mobile device users, and crowdsensing platform. Crowdsensing platform releases sensing tasks to the mobile device users based on the received information requests. Then, the mobile device users will collect specific local information and send it back to the platform. It has been applied in various scenarios, including but not limited to environmental data collecting, human activity recognition, traffic monitoring, navigation, indoor localization, and indoor floorplan construction. A critical problem in improving the quality and effectiveness of crowdsensing is to decide which users to select to perform sensing tasks, in order to obtain the most informative data, while maintaining the total sensing costs below a given threshold. To solve this problem, the key challenges lie in (1) finding an effective measure of the informativeness of the users' data, (2) learning users' sensing costs which are unknown a priori, and (3) designing an efficient user selection algorithm that achieves low-regret guarantees. In this paper, to solve the first challenge, we adopt Gaussian Processes (GPs) to model spatial environmental locations, and provide a mutual information-based criterion to characterize the users' informativeness. To tackle the second and third challenge, we model the problem as a budgeted Multi-Armed Bandit (MAB) problem based on stochastic assumptions. In the problem model, we assume that each user's

收稿日期:2019-01-15;在线出版日期:2019-11-07. 本课题得到“物联网与智慧城市关键技术及示范”重点专项(2019YFB2102200)、国家自然科学基金项目(61972252,61972254,61672353,61672348)、阿里巴巴创新研究计划资助. 杨 朔,博士,中国计算机学会(CCF)会员,主要研究方向为移动计算、无线网络. E-mail: wnmxy@sjtu.edu.cn. 吴 帆(通信作者),博士,教授,中国计算机学会(CCF)会员,主要研究领域为网络经济学、无线网络、移动计算、隐私安全. E-mail: fwu@cs.sjtu.edu.cn. 陈贵海,博士,教授,中国计算机学会(CCF)会士,主要研究领域为分布式计算、计算机网络、并行计算.

sensing cost follows an unknown distribution with unknown mean. The platform receives the knowledge of a user's sensing cost after the user finishes its sensing task. In this case, the platform needs to learn the users' sensing costs and make decisions in an online manner. This problem is NP-hard even if the full knowledge of the users' sensing costs is available. To address the NP-hardness of the problem, we first consider an ideal full-knowledge scenario, and propose efficient greedy algorithms with constant approximation ratios for both single-rounded and multi-rounded user selection scenarios. Then, based on the full-knowledge user selection algorithms, we design two multi-armed bandit algorithms for static and dynamic scenarios respectively with theoretically proven low-regret guarantees. Our evaluation results show that our algorithm can efficiently select most informative users under stringent constraints, improving the performance up to about 20% compared with the benchmarks.

Keywords mobile crowdsensing; user selection; multi-armed bandit; budget constraint; spatial correlation

1 引 言

智能手机的快速普及和无线通信技术的发展正在改变我们收集数据的方式. 大多数智能手机和可穿戴设备都装配有不同种类的传感器, 如 GPS、加速度传感器、陀螺仪、距离传感器、麦克风、温度传感器等. 这些传感器能够被用来收集用户的周边环境信息和用户的行为模式. 移动群智感知^[1]作为一种新兴的感知模式, 通过利用用户移动设备进行信息采集和信息共享, 已经被广泛运用到多种实际应用场景, 包括室内定位^[2-3]、环境监测^[4]、交通与导航^[5-6]、室内平面图构建^[7]等.

移动群智感知研究中的一个关键问题在于: 如何尽可能降低所收集数据中的冗余信息, 即如何通过用户选择来达成数据信息量的最优. 一方面, 空间统计学^[8]告诉我们, 距离较近的两个地点的环境状况通常较为相似, 因此如果某个位置的数据已经被采集, 那么采集该位置附近位置的数据往往意义不大. 另一方面, 在很多情况下, 环境信息存在空间相关性^[9], 因此我们可以对空间环境建模, 利用已观测地点的信息预估未观测地点的环境状况. 因此, 在移动群智感知中, 从众多用户中选取最有信息量的一组用户来进行感知任务, 能够最大限度地发挥群智感知的效能, 对群智感知平台的后续数据分析和利用有着重要意义. 特别地, 在总预算有限的条件下, 如何最有效地利用预算来进行用户选择, 是移动群智感知研究亟需解决的重要问题. 解决该问题需要克服以下三点关键挑战:

第一点挑战在于如何决定用户酬劳. 在移动群

智感知中, 用户进行感知任务不仅需要付出时间成本和劳动力成本, 同时还有资源成本(如电池消耗、网络流量消耗等). 为了激励用户的参与, 群智感知平台往往向用户支付一定的酬劳. 在预算有限的情况下, 如何选择用户并确定用户酬劳, 常规的方法是利用已有的预算可行性机制研究^[10-11]. 此类方法主要基于逆向拍卖机制(如文献^[10-13]), 即用户向平台提交报价, 平台再根据用户的报价决定用户选择和用户酬劳, 并通过设计有效的博弈论机制保证用户不会在出价上进行欺诈. 此类模型的缺陷在于, 平台计算出来的用户酬劳只与用户的主观报价有关, 而不能客观反映用户参与感知任务的实际成本以及用户数据给平台带来的效益. 文献^[14-15]指出, 平台支付给用户的酬劳, 不仅应与用户的劳动力消耗和时间消耗有关, 也应考虑用户的数据质量. 比如, 在其他条件相同的情况下, 提供更高质量数据的用户, 应获得更高酬劳. 在本文中, 我们采用不同于逆向拍卖的酬劳计算方法, 而采用基于用户实际消耗和数据质量的酬劳分配方法, 即在用户完成感知任务后, 群智感知平台收集用户数据并采用已有的资源消耗衡量方法^[16]和数据质量检测方法^[17-18]来量化用户的感知成本和数据质量, 并依此决定用户酬劳.

第二点挑战是平台缺乏对用户感知成本和数据质量的先验知识. 因此, 只有当用户完成感知任务后, 平台才能进行相应的计算和分析来决定用户酬劳. 在这种情况下, 群智感知平台需要对用户的实际消耗、数据质量以及用户酬劳进行实时地学习和计算. 在实际应用中, 平台通常将感知任务从时间上切分成多个轮次, 在每一轮开始的时候选择一组用户来进行本轮的数据收集, 在该轮次结束后收集用户

数据,并按照预先拟定的计算方法决定用户酬劳.与此同时,平台还将不断地学习用户的选择成本(即选择用户后需要支付给该用户的酬劳),并在下一轮开始前根据用户的选择成本来决定用户选择.在这样的多轮任务场景下,如何准确地学习用户选择成本,以及如何有效地利用预算来最大化数据信息量需要仔细研究.

第三,用户选择成本先验知识的缺乏造成了用户选择过程中的另一个挑战:如果平台已经探索到了一些低成本且高信息量的用户,那么他们是持续选择这些优质用户,还是试图选择其他用户以期找到更低成本、更高信息量的用户呢?这是强化学习中经典的“探索和利用”的难题,即一个主体需要决定是探索其他行为以试图获得关于其他行为的更多信息,还是继续利用已知的有效的行为.

在本文中,我们综合考虑以上三点挑战,将问题建模为多轮次信息量最大化的用户选择问题,其中群智感知平台缺乏用户选择成本的先验知识,同时平台支付给用户的总酬劳需有一定的预算上限.为了衡量用户信息量,我们采用高斯模型对空间环境进行建模,提出一个基于互信息的信息量衡量指标,并证明该信息量衡量指标是一个非负单调的子模函数.为了解决最大化信息量的用户选择难题,我们首先考虑理想情况下的用户选择问题,即如何在用户选择成本已知的情况下最有效地利用预算来最大化总信息量.该问题为 NP-难问题,为了解决这个问题,我们提出了一个近似比为 $(1-1/e)/2$ 的近似算法.接着,我们考虑用户选择成本先验知识缺失的实际情况.为了解决该场景下的探索和利用的难题,我们将用户选择问题建模成多臂老虎机问题模型,并提出两个有预算限制的用户选择算法,分别叫做 BIM-ST 和 BIM-DY. BIM-ST 考虑静态用户场景,即用户的位置在整个感知过程中保持不变,而 BIM-DY 允许用户在不同轮次位置不同.我们证明了所提出的算法在渐进情况下能够达到零的累计遗憾.实验结果也表明我们的算法能够在不同设定下都能够取得近似最优的总信息量.

本文的主要贡献如下:

(1) 我们考虑了群智感知中信息量最大化的用户选择问题,其中,平台缺乏用户选择成本的先验知识,同时选择用户的总成本需要控制在一定的预算范围内.我们采用高斯过程来建模空间环境,并提出基于互信息的指标来衡量信息量;

(2) 我们首先提出一个理想的完备知识情况下

的多轮最大信息量用户选择算法,该算法能够达到常数级别的近似比;

(3) 在缺乏用户成本先验知识的情况下,我们提出两个多臂老虎机的用户选择算法.它们考虑不同的用户移动场景,并都达到零累计遗憾的特性;

(4) 在不同设定情况下的实验结果表明我们提出的用户选择算法能够有效地利用预算提高数据信息量,与基准方法相比效果提高约 20%.

2 问题模型

在本节中,我们介绍信息量最大化的用户选择问题模型.其中,2.1 节给出模型的定义,2.2 节定义信息量衡量指标,2.3 节描述如何运用高斯过程对空间环境进行建模,2.4 节给出基于多臂老虎机的用户选择问题模型.

2.1 基本定义

一个典型的群智感知系统架构有三个组成部分:服务需求者、移动设备用户、和群智感知平台.在接收到服务需求者的信息需求后,群智感知平台发布特定感知任务给移动设备用户.简单起见,我们仅考虑一个感知任务,比如监测某公园的环境噪音.假设该感知任务由 T 轮组成,每轮的时间长度相同.我们将指定的感知区域网格化为一组离散感知地点 $L = \{l_1, l_2, \dots, l_m\}$.

用户通过移动设备应用与平台进行交互,用户可以在移动设备上查看平台发布的感知任务,并选择感兴趣的任务参加.假设有一组 $N = \{1, 2, \dots, n\}$ 的用户加入该感知任务.在每一轮 $t \in \{1, 2, \dots, T\}$ 开始前,平台会从用户集合中选取部分用户 $S_t \subseteq N$ 执行该轮的感知任务.在每轮 t 结束后,用户 $i \in S_t$ 会将感知数据提交给平台并收到相应的酬劳 $p_{i,t}$.用户的实时位置由手机的 GPS 监测,并通过 WiFi 或蜂窝网络共享给平台.在每一轮中,我们假设每一个选中的用户 $i \in S_t$ 地点在本轮不变,记作 $l_{i,t}$.

群智感知系统的目标是在给定的预算 B 范围内,最大化收集到数据的总信息量.我们用 $F(S)$ 来表示一组用户 $S \subseteq N$ 数据的信息量.该问题的数学表达如下:

$$\max_{S_t \subseteq N} \sum_{t=1}^T F(S_t), \text{ subject to } \sum_{t=1}^T \sum_{i \in S_t} p_{i,t} \leq B \quad (1)$$

2.2 信息量衡量指标

对用户信息量的衡量,一种简单的方法是假设每个用户都有一个确定的感知半径,从而将信息量

最大化问题转换为最大覆盖问题^[19]. 然而这种方法并不适用于面向环境监测的群智感知系统, 因为环境现象的空间相关性较为复杂, 不能简单地用规则的圆形区域来刻画^[20-21].

在本文中, 我们采用基于互信息^[22]的衡量指标来刻画用户的信息量. 我们用随机变量 X_{l_s} 来表示每个地点 $l_s \in L$ 的环境状况. 对于一组用户 $S \subseteq N$, 我们用 $L_S \subseteq L$ 来记录这组用户的位置集合, 相应的 X_{L_S} 则表示位置集合 L_S 环境信息的随机变量集合. 在不引起歧义的前提下, 为了简化数学符号, 我们用 l_s 来代替 X_{l_s} , 用 L_S 来替代 X_{L_S} . 在正式给出互信息的定义前, 我们简单回忆一下熵的概念.

定义 1. 熵^[22]. 一个随机变量 X 的(差分)熵定义为

$$H(X) = - \int_X p(x) \log p(x) dx \quad (2)$$

熵是一个衡量随机变量不确定度的指标, 也可以作为一种简单的信息量衡量指标. 然而, 文献^[23]指出, 基于熵最大化的用户选择方法会倾向于选择感知空间边界上的用户, 从而造成信息损失. 为了解决这个问题, 基于互信息的信息量度量指标被提出, 并被广泛应用在多种场景中, 包括传感器部署^[20-21]、特征提取^[24]等.

定义 2. 互信息^[22]. 两个随机变量 X 和 Y 之间的互信息 $I(X; Y)$ 被定义为

$$I(X; Y) = \int_Y \int_X p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (3)$$

从直觉上理解, 互信息刻画的是随机变量 X 和 Y 之间共享的信息, 即知道其中一个随机变量能够降低另一个随机变量的不确定性的程度. 例如, 如果 X 和 Y 相互独立, 那么知道 X 不能给出 Y 的任何信息, 反之亦然, 因此它们的互信息是零. 在空间环境监测中, 假设我们已经部署了一组用户 $S \subseteq N$ 来进行环境状况检测, 那么已观测地点 L_S 和未观测地点 $L \setminus L_S$ 的互信息 $I(L_S; L \setminus L_S)$ 表示了观测 L_S 能够给出多少未观测地点 $L \setminus L_S$ 的信息. 根据式(2)和式(3), 我们有

$$I(X; Y) = H(X) + H(Y) - H(X, Y) \quad (4)$$

其中 $H(X, Y) = -E[\log p(X, Y)]$ 是 X 和 Y 的联合熵. 我们定义信息量衡量指标如下:

$$F(S) = I(L_S; L \setminus L_S) \quad (5)$$

因此选取信息量最大的一组用户就等同于选择一组用户 S 使得 L_S 和 $L \setminus L_S$ 的互信息最大.

2.3 多变量高斯分布和高斯过程

在环境监测中, 通常我们不仅仅想要预测环境

状况的值, 同时还想知道它们的概率分布, 这样平台才能够向服务需求者提供环境状况的预测值及其置信区间. 为了解决这个问题, 一个简单且有效的方法是假设观测现象服从一个联合的多变量高斯分布^[9], 即 m 个离散地点的随机变量 $X_L = \{X_{l_1}, X_{l_2}, \dots, X_{l_m}\}$ 的联合概率分布为

$$P(X_L = x_L) = \frac{1}{(2\pi)^{m/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(x_L - \mu)^T \Sigma^{-1} (x_L - \mu)} \quad (6)$$

其中 μ 是均值向量, Σ 是协方差矩阵, $|\Sigma|$ 是协方差矩阵的行列式. 由于联合高斯分布的条件概率分布也是高斯分布, 因此如果在某轮 t 中, 我们已经观测到部分地点 $L_t \subseteq L$ 的值, 则对某个未观测地点 $l_s \in L \setminus L_t$, 它的条件均值 $\mu_{l_s | L_t}$ 和条件方差 $\sigma_{l_s | L_t}^2$ 可以表示为

$$\mu_{l_s | L_t} = \mu_{l_s} + \Sigma_{l_s L_t} \Sigma_{L_t L_t}^{-1} (x_{L_t} - \mu_{L_t}) \quad (7)$$

$$\sigma_{l_s | L_t}^2 = \sigma_{l_s}^2 - \Sigma_{l_s L_t} \Sigma_{L_t L_t}^{-1} \Sigma_{L_t l_s} \quad (8)$$

其中, $\Sigma_{l_s L_t}$ 是 l_s 与 L_t 中所有变量的协方差向量. $\Sigma_{L_t L_t}$ 是一个协方差矩阵, 其中每一项 $\Sigma_{u,v}$ 代表了 u 和 v 的协方差.

在某些情况下, 我们不仅感兴趣感知空间中指定位置的环境状况, 同时还感兴趣指定位置以外地点的信息. 在这种情况下, 我们采用高斯过程将多变量高斯分布泛化至无穷数量的随机变量. 以噪声检测为例, 我们有无穷数量的位置, 即 $L \subseteq R^2$, 并且每一个位置 l_s 都有一个随机变量 X_{l_s} 表示该位置的噪声信息. 我们的高斯过程由一个均值函数 $M(\cdot)$ 和一个对称正定的核函数 $K(\cdot, \cdot)$ 组成. 对每一个随机变量 X_u , $M(u)$ 代表了它的均值; 对于任意两个随机变量 X_u 和 X_v , $K(u, v)$ 代表它们的协方差.

给定一组 k 个随机变量的集合 X_{L_S} , 如果它们遵循多变量高斯分布, 均值向量为 μ_S , 协方差矩阵为 Σ_{SS} , 则这组随机变量的差分熵为

$$H(X_{L_S}) = \frac{1}{2} \log((2\pi e)^k |\Sigma_{SS}|) \quad (9)$$

根据式(4)和式(9), 我们就可以计算出已观测位置和未观测位置的互信息. 因此, 当我们选定一组用户进行感知任务后, 我们就可以根据这组用户的地理位置计算它们数据的信息量. 通过选择合适的用户, 我们可以有效地提升所收集数据的信息量, 降低未观测位置环境信息的不确定性, 提升用户选择的效益.

2.4 多臂老虎机模型

在实际的群智感知过程中, 平台支付给用户的酬劳受多个因素影响, 包括但不限于用户的时间成本、劳动力成本、设备资源消耗以及用户的数据质

量. 在每一轮结束后, 平台会根据这些信息综合计算需要支付给用户的酬劳. 其中, 用户软硬件资源消耗能够通过设备的资源管理器获得, 用户的时间成本等信息可以采取按固定费用支付^[12], 用户的数据质量可以采用已有的数据质量衡量方法进行计算^[14-15, 25]. 在每一轮 t 结束以后, 平台采用事先约定的酬劳计算方案计算每个用户 i 的酬劳, 记作 $p_{i,t}$. 具体计算公式可根据平台的实际需求决定.

我们注意到, 支付给每个用户的酬劳, 即用户选择的成本是在每轮结束以后才能知道. 然而, 平台需要在每轮开始前进行用户选择, 而此时平台并没有用户选择成本的确切信息. 在这种情况下, 我们需要设计一种在线学习方法来不断地学习用户成本, 并在每一轮开始前根据预估的用户成本决定本轮所要选择的用户. 多臂老虎机模型^[26] (Multi-Armed Bandit) 为解决该问题提供了思路.

用户选择成本先验知识的缺失, 给我们带来了“探索和利用”的困境. 文献[27]最早开始研究此问题, 并将其建模为多臂老虎机模型. 在经典的随机多臂老虎机模型中^[28], 一台老虎机有多个异质的拉杆, 下拉每一个拉杆都会按照某个未知的概率分布产生一个随机的报酬. 玩家进行多次拉杆操作而使得自己的累计遗憾最小化, 其中“累计遗憾”被定义为实际收益与拥有完备信息的理想情况(即已知每个拉杆能产生的酬劳)下的最优收益之间的差值. 当拉拉杆的次数趋向无穷大时, 如果一个策略能够使平均累计遗憾趋向于零, 则称该策略达到了零累计遗憾.

在我们的问题中, 我们将群智感知中的用户当成 n 个异质的拉杆. 在每一轮中, 选择一个用户 i 会产生一定的选择成本, 即需要支付给用户的酬劳 $p_{i,t}$. 我们假设每个用户 i 的酬劳都遵循某个未知的概率分布, 概率分布的期望 p_i 是未知量. 在每一轮 t 开始时, 群智感知平台需要选择一组用户 $S_t \subseteq N$ 来进行感知任务, 在该轮结束后平台会收集用户数据、计算用户的酬劳、并更新用户选择成本的估计.

多臂老虎机问题在学术界被广泛研究, 目前有多种不同的多臂老虎机算法^[29-39]. 然而, 我们的问题模型与已有的多臂老虎机研究工作有所差异. 第一, 大多数的多臂老虎机算法假设玩家每轮只拉一个或者固定数量的拉杆, 然而在我们的问题中, 群智感知平台每一轮选择的用户的数量是不确定的. 尽管组合多臂老虎机的研究^[34]可以用来解决不确定数量拉杆的问题, 但是此类算法并没有考虑预

算限制. 第二, 已有多臂老虎机的研究通常考虑线性^[29-33, 36]或者对称^[35, 38-39](即函数输出只和输入集合的大小有关)的优化函数, 然而我们提出的基于互信息的优化目标是一个非线性的子模函数, 因此在算法设计和分析上更具挑战. 第三, 现有的预算限制下的多臂老虎机问题模型通常考虑缺失拉杆酬劳的先验知识(优化目标中存在未知量), 而在我们问题考虑缺乏每个用户选择成本的先验知识(限制条件中存在未知量).

3 完备信息下的用户选择算法

在本节中, 我们考虑用户选择成本信息已知的理想情况下. 尽管该假设在实际场景中并不成立, 但我们在本节所提出的用户选择算法是后文实际场景下用户选择算法的基础. 我们在 3.1 节中首先考虑单轮次的信息量最大化用户选择算法, 并在 3.2 节中将其拓展至多轮场景.

3.1 单轮有预算的信息量最大化用户选择算法

我们首先给出子模函数的定义. 子模函数是一种函数边际增长随着输入集合大小增大而减小的函数, 也就是说, 当函数输入集合的大小不断变大时, 函数值的边际增长量会逐渐减小.

定义 3. 子模函数. 给定函数 $F: 2^N \rightarrow \mathbb{R}$, 如果对任意集合 $A, B, A \subseteq B \subseteq N, \forall i \in N \setminus B$, 都有

$$F(A \cup \{i\}) - F(A) \geq F(B \cup \{i\}) - F(B) \quad (10)$$

则函数 F 是一个子模函数.

尽管互信息本身并不是一个子模函数^[40], 我们提出的基于互信息的信息量衡量指标 $F(L_S) = I(L_S; \mathcal{L} \setminus L_S)$ 却是一个非负的子模函数. 同时, 函数 F 在 L_N 上也是非递减的函数^[20].

引理 1. 函数 $F(L_S) = I(L_S; \mathcal{L} \setminus L_S)$ 是一个非负的子模函数.

证明. 根据互信息的定义, F 显然是非负的. 接下来, 我们证明函数 F 是一个子模函数. 对于任意的集合 $A, B, A \subseteq B \subseteq L$, 对于任意 $s \in L \setminus B$, 我们有

$$\begin{aligned} & F(A \cup \{s\}) - F(A) \\ &= I(A \cup \{s\}; \mathcal{L} \setminus (A \cup \{s\})) - I(A; \mathcal{L} \setminus A) \\ &= H(A \cup \{s\}) - H(A) + [H(\mathcal{L} \setminus (A \cup \{s\})) - H(\mathcal{L} \setminus A)] \\ &= H(\{s\} | A) - H(\{s\} | \mathcal{L} \setminus (A \cup \{s\})). \end{aligned}$$

注意到 $H(\{s\} | A) \geq H(\{s\} | B)$, 以及

$$H(\{s\} | \mathcal{L} \setminus (B \cup \{s\})) \geq H(\{s\} | \mathcal{L} \setminus (A \cup \{s\})).$$

我们有

$$F(A \cup \{s\}) - F(A) \geq F(B \cup \{s\}) - F(B).$$

因此 F 是一个非负的子模函数。证毕。

当群智感知任务仅有单轮次时,我们只需要一次性地从用户集合中选择一个子集来最大化信息量,同时满足预算的限制.其数学表达如下:

$$\arg \max_{S \subseteq N} F(S), \text{ subject to } \sum_{i \in S} p_i \leq B \quad (11)$$

即使选择用户的成本 p_i 是已知的,该问题也是一个 NP-难问题^[41]. 一个简单的贪心策略是每次选择边际信息量增量最高的用户加入被选集合,直至预算耗尽.然而该策略的近似比缺少上界.为此,我们提出了一个改进的贪心算法,能够取得 $(1-1/e)/2$ 的常数近似比.该算法如算法 1 所示.

算法 1. 单轮有预算的信息量最大化算法.

输入: 总预算 B 和用户的选择成本 $\{p_i\}$

输出: 所选用用户集合 S

步骤:

1. $i^* \leftarrow \arg \max_{i \in N, p_i \leq B} F(\{i\})$
2. $S' \leftarrow \{i^*\}, S'' \leftarrow \emptyset, N' \leftarrow N, B' \leftarrow B$
3. WHILE $N' \neq \emptyset$ DO:
4. $i^* \leftarrow \arg \max_{i \in N'} \frac{F(S'' \cup \{i\}) - F(S'')}{p_i}$
5. IF $B' \geq p_{i^*}$ THEN:
6. $S'' \leftarrow S'' \cup \{i^*\}$
7. $B' \leftarrow B' - p_{i^*}$
8. END IF
9. $N' \leftarrow N' \setminus \{i^*\}$
10. END WHILE
11. 返回 $\arg \max_{S' \in \{S', S''\}} F(S)$

3.2 多轮有预算的信息量最大化用户选择算法

多轮次的用户选择问题,如式(1)所示,由于需要考虑如何在 T 轮中进行预算分配,因而更具挑战性.一种简单的方法是将预算平均分配到 T 轮,然而这种方法的近似比没有上界.我们举例说明:考虑一个简单的两轮次的群智感知场景,假设只有两个用户,记作 n_1 和 n_2 . 两个用户的选择成本分别是 2 和 1. 假设这两个用户的位置都固定,他们的信息量分别是一个远大于 1 的数 o 和 1. 如果总预算是 2,那么最优方案应该是第一轮选择 n_1 ,第二轮不进行用户选择,从而得到的最优的信息量是 o . 然而,如果我们将预算平均分配到两轮中,那么在每轮都只能选择 n_2 ,取得的总信息量为 2. 在这种情况下近似比是 $o/2$. 由于 o 可以任意大,因此该算法的近似比没有上界.

为了解决多轮有预算情况下的信息量最大化问

题,我们对单轮的选择算法进行修改,将其推广至多轮用户选择,并且维持 $(1-1/e)/2$ 的近似比.该算法如算法 2 所示.我们在每一轮进行该轮次的用户选择时,会将未来多轮的用户选择考虑在内.对于每一个用户 $i \in N$,我们用一个 T 维的向量 ϕ_i 来表示该用户在整个 T 轮的被选择情况,其中 $\phi_{i,t} \in \{0, 1\}$ 表示用户 i 在第 t 轮是否被选择(1 表示是,0 表示否).我们用 Φ 表示 ϕ_i 的全排列.我们定义 $|\phi_i|$ 表示用户 i 在整个 T 轮被选择的总次数.我们将所有用户的被选择情况的集合 $\{\phi_1, \phi_2, \dots, \phi_n\}$ 记作 V . 有了这些定义,多轮次的用户选择问题可以被改写为

$$G(V) = \sum_{t=1}^T F(S_t) \quad (12)$$

其中 $S_t = \{i \mid \phi_{i,t} = 1, i \in N, \phi_i \in V\}$. 由于多个单调子模函数的和也是单调子模函数,因此 G 函数也是一个非负非递减的单调子模函数.现在,我们的问题转化成在预算限制下选择一个用户选择的实例 V' ,使得子模函数 G 的值最大.

算法 2. 多轮有预算的信息量最大化算法.

输入: 总预算 B , 轮次 T , 和用户的选择成本 $\{p_i\}$

输出: 用户选择实例 $\{\phi_i\}, \forall i \in N$

步骤:

1. $\langle i^*, \phi_i^* \rangle \leftarrow \arg \max_{i \in N, \phi_i \in \Phi, |\phi_i| p_i \leq B} G(\{\phi_i\})$
2. $V' \leftarrow \{\phi_i^*\}, V'' \leftarrow \emptyset, N' \leftarrow N, B' \leftarrow B$
3. WHILE $N' \neq \emptyset$ DO
4. FOR EACH $i \in N'$ DO
5. IF $B' \geq p_i$ THEN
6. $\phi_i^* \leftarrow \arg \max_{\phi_i \in \Phi, |\phi_i| p_i \leq B'} G(V'' \cup \{\phi_i\}) - G(V'')$
7. ELSE $N' \leftarrow N' \setminus \{i\}$
8. END
9. END FOR
10. IF $N' \neq \emptyset$ THEN
11. $i^* \leftarrow \arg \max_{i \in N'} \frac{G(V'' \cup \{\phi_i^*\}) - G(V'')}{|\phi_i^*| p_i}$
12. $V'' \leftarrow V'' \cup \{\phi_i^*\}$
13. $N' \leftarrow N' \setminus \{i^*\}$
14. $B' \leftarrow B' - |\phi_i^*| p_i$
15. END IF
16. END WHILE
17. 返回 $\arg \max_{V \in \{V', V''\}} G(V)$

多轮算法的思想和单轮算法的思想类似.对于每一个用户,我们首先计算该用户的被选实例 $\phi_i^* \in \Phi$,使得在当前用户选择情况 V'' 下的边际信息量增量 $G(V'' \cup \{\phi_i^*\}) - G(V'')$ 最大(算法第 6 行).然后,我们贪婪地选择边际信息量增益最大的用户 i^* (算

法第 11 行). 最后, 该贪婪的选择结果与只选择一个用户能够达到的效果进行比较, 效果更好的用户选择作为我们最终的选择方案.

定理 1. 我们提出的多轮有预算的信息量最大化用户选择算法能够在多项式的时间复杂度内达到 $(1-1/e)/2$ 的近似比.

证明. 近似比的证明过程可参考单轮算法的近似比证明^[40].

4 基于多臂老虎机的用户选择算法

在本节中, 我们考虑缺失用户选择成本先验知识的实际情况. 我们提出两个多臂老虎机算法, 分别叫做 BIM-ST 和 BIM-DY. BIM-ST 假设用户的位置在整个群智感知过程中固定, 而 BIM-DY 允许用户在不同轮次间移动.

4.1 BIM-ST

在缺乏选择用户成本先验知识的条件下, 我们需要不断地学习用户成本. 为此, 我们提出一个简单有效的方法来解决探索与利用的难题. 该算法的主体思想是分配部分预算 $B' = \epsilon B$ 来进行探索, 剩余的预算则用来进行最优选择. 我们假设用户的位置固定, 则每个用户的信息量在群智感知过程中不会发生变化.

我们的算法如算法 3 所示. 它包括探索和利用两个阶段. 在探索阶段, 我们每轮都选择所有的用户并学习这些用户的成本, 同时预估探索阶段的预算是否可以支持下一轮探索. 探索阶段结束后, 我们计算每个用户的选择成本的均值, 将该均值作为用户成本分布的真实均值. 然后, 我们在剩余预算的情况下, 利用算法 2 进行最优用户选择.

算法 3. BIM-ST.

输入: 总预算 B , 成本上界 p_{\max} 和常数 ϵ

输出: 所选用户集合 $\{S_1, S_2, \dots, S_T\}$

步骤:

1. $B' \leftarrow \epsilon B, B'' \leftarrow (1-\epsilon)B, T' \leftarrow 0$

//探索阶段

2. WHILE $B' \geq np_{\max}$ and $T' < T$ DO

3. $T' \leftarrow T' + 1$

4. $S_{T'} \leftarrow N$

5. $B' \leftarrow B' - \sum_{i \in S_{T'}} p_{i, T'}$

6. END WHILE

//利用阶段

7. $\hat{p}_i \leftarrow \sum_{t=1}^{T'} p_{i, t} / T', \forall i \in N$

8. $B'' \leftarrow B'' + B'$

9. $V \leftarrow \text{Alg}_2(B'', T - T', \{\hat{p}_i\})$

10. 根据 V 计算 $S_t, \forall t \geq T' + 1$

11. 返回 $\{S_1, S_2, \dots, S_T\}$

为了评估算法 BIM-ST 的效果, 我们需要分析算法的累计遗憾. 累计遗憾被定义为在理想情况下的最优结果与算法所取得结果之间的差值. 由于信息量最大化问题是 NP-难问题, 最优结果往往很难得到. 为了解决这个问题, 我们采用 α -近似累计遗憾的指标来分析 BIM-ST 算法.

定义 4. α -近似累计遗憾^[34,42]. 给定用户选择策略 $\{S_1, \dots, S_T\}$, 该策略的 α -近似累计遗憾被定义为

$$R_\alpha = \alpha \cdot \sum_{t=1}^T F(S_t^*) - \sum_{t=1}^T F(S_t) \quad (13)$$

其中 $\{S_1^*, S_2^*, \dots, S_T^*\}$ 是理想情况下的最优用户选择策略.

α -近似累计遗憾的直观解释是, 所提出算法的累计遗憾不与理想情况下的最优策略比较, 而是与 α -近似的算法进行比较. 基于上述定义, 我们分析 BIM-ST 算法的 $(1-1/e)/2$ -近似累计遗憾.

定理 2. BIM-ST 算法的 $(1-1/e)/2$ -近似累计遗憾是 $(T - \lfloor B/(np_{\max}) \rfloor)F(N)$.

证明. 我们用 $\text{Alg}_2(B, T, \{p_i\})$ 来表示算法 2 在预算为 B 、轮次为 T 轮、且用户选择成本为 $\{p_i\}$ 的条件下所取得的总信息量. 假设探索的轮次为 T' . 在用户选择成本事先未知的情况下, BIM-ST 能够取得的信息量为

$$T'F(N) + \text{Alg}_2\left(B - \sum_{t=1}^{T'} \sum_{i \in N} p_{i, t}, T - T', \{\hat{p}_i\}\right),$$

其中 $\{\hat{p}_i\}$ 是预估的用户选择成本. 在上式中, 第一项和第二项分别表示算法在探索和利用阶段所取得的信息量.

根据 Hoeffding 不等式, 对于任意用户 $i \in N$, 任意 δ_i , 我们有

$$P(|p_i - \hat{p}_i| \geq \delta_i) \leq e^{-2T'\delta_i^2}.$$

令 $\delta_i = \sqrt{\frac{-\ln\beta}{2T'}}$, 可证明对于任意 $i \in N$, $|p_i - \hat{p}_i| \leq \delta_i$ 有 $(1-\beta)^n$ 概率成立. 通过选择一个合适的 p_{\max} , 我们可以得到 $\forall i \in N, p_{\max} \geq \hat{p}_i$ 有 $(1-\beta)^n$ 的概率成立.

令 $B'' = B - \sum_{i=1}^T \sum_{i \in N} p_{i, t}$, 可以看出在利用阶段, 按照算法 2 达到的效果不小于利用该阶段预算选择所有用户, 即

$$\text{Alg}_2(B'', T - T', \{\hat{p}_i\}) \geq \left\lfloor \frac{B''}{np_{\max}} \right\rfloor F(N).$$

因此,可以得到

$$T'F(N) + \text{Alg}_2(B'', T - T', \{\hat{p}_i\}) \geq \left\lfloor \frac{B}{np_{\max}} \right\rfloor F(N).$$

由于算法 2 的近似比是 $(1-1/e)/2$, 可以得到累计遗憾的上界是 $2\text{Alg}_2(B, T, \{p_i\})/(1-1/e) \leq TF(N)$. 因此 BIM-ST 算法的累计遗憾为

$$(T - \lfloor B/(np_{\max}) \rfloor)F(N). \quad \text{证毕.}$$

注意到, 当 B 和 T 同时趋向无穷大时, BIM-ST 算法的平均累计遗憾趋向于零, 因此该算法达到“零累计遗憾”特性.

4.2 BIM-DY

在某些情况下, 用户在不同轮次的位置可能会出现变化, 因此用户的信息量在不同轮次可能会出现较大差异. 在这种情况下, 我们只能在每轮开始前评估用户的信息量, 而无法运用类似算法 3 的静态算法.

为了解决这个问题, 我们把利用阶段的预算分配到每一轮. 在利用阶段的每一轮, 我们收集用户的地理位置, 计算用户的信息量, 根据探索阶段学到的用户选择成本运用单轮有预算的信息量最大化算法进行用户选择. 此外, 利用阶段中每一轮剩下的预算会被分配到后续轮次. 算法如算法 4 所示.

算法 4. BIM-DY.

输入: 总预算 B , 成本上界 p_{\max} 和常数 ϵ

输出: 所选用用户集合 $\{S_1, S_2, \dots, S_T\}$

步骤:

1. $B' \leftarrow \epsilon B, B'' \leftarrow (1-\epsilon)B, T' \leftarrow 0$
2. WHILE $B' \geq np_{\max}$ and $T' < T$ DO
3. $T' \leftarrow T' + 1$
4. $S_{T'} \leftarrow N$
5. $B' \leftarrow B' - \sum_{i \in S_{T'}} p_{i, T'}$
6. END WHILE
7. $\hat{p}_i \leftarrow \sum_{t=1}^{T'} c_{i, t} / T', \forall i \in N$
8. $B'' \leftarrow B' + B''$
9. FOR $t = T' + 1$ to T DO
10. $S_t \leftarrow \text{Alg}_1(B'' / (T - t + 1), \{\hat{p}_i\})$
11. $B'' \leftarrow B'' - \sum_{i \in S_t} p_{i, t}$
12. END FOR
13. 返回 $\{S_1, S_2, \dots, S_T\}$

我们将 BIM-DY 与拥有用户选择成本完备信息的理想情况下的基准方法进行比较, 该基准方法

直接运行 BIM-DY 而无须进行探索阶段.

定理 3. BIM-DY. 算法的 $(1-1/e)/2$ -近似累计遗憾是 $(T - \lfloor B/(np_{\max}) \rfloor)F(N)$.

证明. 我们用 $\text{Alg}_1(B, \{p_i\})$ 来表示算法 1 在预算为 B 且选择用户成本为 $\{p_i\}$ 时取得的信息量. 假设 BIM-DY 的探索阶段有 T' 轮. 在用户选择成本未知的情况下 BIM-DY 能够取得的信息量为

$$T'F(N) + (T - T') \text{Alg}_1 \left[\frac{B - \sum_{t=1}^{T'} \sum_{i \in N} p_{i, t}}{T - T'}, \{\hat{c}_i\} \right],$$

其中上式的第一项和第二项分别表示 BIM-DY 在探索阶段和利用阶段所取得的信息量.

令 $B'' = (B - \sum_{i=1}^{T'} \sum_{i \in N} p_{i, t}) / (T - T')$, 我们有

$$T'F(N) + (T - T') \text{Alg}_1(B'', \{\hat{p}_i\}) \geq \left\lfloor \frac{B}{np_{\max}} \right\rfloor F(N).$$

由于基准算法所取得的信息量不会超过 $TF(N)$, 因此累计遗憾的上界为 $(T - \lfloor B/(np_{\max}) \rfloor)F(N)$. 证毕.

可以看出, 当 T 和 B 趋向无穷时, BIM-DY 算法的平均累计遗憾趋向 0, 因此该算法也达到了“零累计遗憾”的特性.

5 相关工作

移动群智感知网络在近年来受到学界和工业界的广泛关注, 目前已经被应用在多个不同的实际场景中. 例如, 文献[2]提出一种基于移动群智感知网络的逻辑定位系统, 文献[3]设计了通过利用移动设备追踪室内环境的室内定位技术. 文献[4]提出了一种采用手持移动智能设备来进行空气质量监测的方法. 文献[5]提出了基于移动群智感知的公交到站时间预估系统. 文献[6]提出了基于智能手机感知的城市路边停车位自动寻找系统. 文献[7]利用群智感知数据来构建室内平面图. 文献[1, 43]较好地移动群智感知的发展和应用进行综述.

在理论层面, 移动群智感知也被广泛研究. 文献[13]研究了以平台为中心和以用户为中心的群智感知模型, 并且分别为两种模型设计了激励机制. 文献[11]研究了有预算限制下的群智感知用户选择问题, 并且提出两个在线的预算可行性机制. 文献[44]研究了群智感知中的信誉系统设计, 并提出无监督学习方法刻画用户的数据质量和信誉. 文献[45]将数据质量引入群智感知的激励机制设计, 并提出激励相容的组合机制. 文献[25]考虑了群智感知中基

于数据质量的定价问题,并提出一个 EM 算法量化用户的数据质量.文献[46]考虑了大规模群智感知系统中的动态用户选择问题.文献[47]考虑了群智感知中用户移动的时空相关性和地理位置相关的动态任务分配策略.文献[48]考虑了在用户移动性不确定情况下的群智感知激励机制设计.然而,已有的工作都没有考虑最大信息量的用户选择算法,也忽视了用户选择成本事先未知的特性.

高斯过程和基于互信息的模型被广泛应用在传感器网络中.在文献[9]中,作者借助高斯过程刻画环境现象的时空相关性,并构建传感器网络的高斯过程概率模型.文献[20]研究了最大化信息量的传感器放置算法,并且采用了基于互信息的传感器选择机制.文献[21]进一步考虑了最大信息量的传感器放置算法,同时最小化传感器之间的通信开销.然而,群智感知网络的场景与传感器网络存在明显差异,不仅仅因为缺乏用户选择成本的先验知识,同时还因为用户的可移动性使得用户选择不同于静态的传感器部署.

多臂老虎机问题(也叫多臂赌博机模型)最早被文献[26]研究,随后的众多研究工作都对该问题进行深入探索,如文献[28,49]等.根据不同的酬劳过程假设,多臂老虎机问题可以分成随机模型、对抗模型、马尔可夫模型.随机模型通常假设每个拉杆的酬劳遵循一个未知的概率分布^[19],对抗模型假设玩家在进行拉臂操作的同时黑心商家会操纵拉杆的酬劳分布^[49],而马尔可夫模型假设拉杆都有其独自的状态空间并遵循马尔可夫过程^[50].经典的随机多臂老虎机算法包括 ϵ -Greedy、 ϵ -First、UCB、汤普森采样算法等,经典的对抗多臂老虎机算法包括 Softmax 策略和 Exp3 算法.文献[26]给出了这些经典算法的详细介绍.根据是否存在辅助信息,多臂老虎机问题可以分为上下文无关多臂老虎机模型和上下文多臂老虎机^[51],其中上下文多臂老虎机则是考虑上下文信息对不同拉杆的影响^[52].在将多臂老虎机模型应用到实际场景中,文献[38]研究了多臂老虎机模型在按点击付费的拍卖中的应用,并讨论了一些算法设计的原则.文献[39]分析了多臂老虎机模型在按点击付费拍卖中的累计遗憾.文献[34]提出了一个通用的组合多臂老虎机模型.文献[29-31]研究了有预算情况下的多臂老虎机问题模型,其中优化的目标是一个线型叠加的函数.文献[53]考虑了移动群智感知中有预算和时间双重限制的多臂老虎机用户选择算法.与已有的多臂老虎机问题模型不同,我们所提出的多臂老虎机模型的优化函数是一个子模

函数,并且每轮选择的用户个数也是不固定的.本文的原始论文发表在 ACM/IEEE IWQoS 2016^[54],本文对原始会议版本进行了大量修改,包括补充完整的数学证明、提出动态用户场景下的算法 BIM-DY 以及附加实验.

6 系统评估

在本节中,我们进行仿真实验来验证所提算法的效果.我们将所提算法与如下三个基准方法进行比较.第一个基准方法(称作 Full-ST 和 Full-DY)是拥有用户选择成本完备知识的理想情况下的贪心算法,同时也是分析近似累计遗憾时的基准方法.与此方法比较的意义在于,从实验层面分析所提算法所取得的信息量与完备知识情况下的差距.第二个基准算法,记作 Bdg-Greedy,是仅从预算角度考虑用户选择的多臂老虎机算法,而忽视了对数据信息量的优化,即平均分配预算至各轮次,并在每轮中贪心地选择最低成本的用户直至预算耗尽.第三个基准算法,记作 Info-Greedy,是仅从信息量最大化角度进行用户选择,而忽视了如何合理地分配预算进行探索和利用.该方法平均分配预算至各轮次,并在每轮中依次贪心地选择边际信息量最大的用户直至预算耗尽.后两个基准方法的引入,有利于检验我们所提出的综合考虑预算和信息量最大化的多臂老虎机优化算法的效果.我们首先在 6.1 节介绍实验设置,然后在 6.2 节陈述实验结果.

6.1 实验设置

我们考虑一个 $1\text{ km} \times 1\text{ km}$ 的方形感知区域.该区域被网格化成 400 个离散位置,每个位置是一个 $50\text{ m} \times 50\text{ m}$ 的网格.假设用户选择成本的均值 p_i 均匀分布在 $[5, 10]$ 中,每个用户的选择成本服从均值为 p_i 、方差为 0.2 的高斯分布.在 BIM-ST 中,用户的起始位置随机分布在感知区域中,并且在整个感知过程中固定.而在 BIM-DY 中,用户的初始位置随机,而在每两轮间可以自由移动.我们进行了一个噪声监测的群智感知仿真实验.由于缺少大规模开源的群智感知数据集,我们的感知数据根据文献[14-15]中的小规模真实实验数据进行高斯分布拟合和采样获得.我们采用高斯过程对环境建模,并采用经典的高斯核作为核函数:

$$K(u, v) = \exp\left(-\frac{\|u, v\|^2}{h^2}\right) \quad (14)$$

其中 $\|u, v\|^2$ 是 u 和 v 的欧几里得距离的平方, h 是一个固定的超参数.在实验中,我们设定 $h=1000$.

我们在 5 种不同的设定下评估算法的效果. 在设定 1 中, 用户的人数以 5 为间隔从 5 增加至 100. 在设定 2 中, 我们将用户人数固定为 50, 预算固定为 500, 而将感知任务的轮次从 5 依次增加值 100. 在设定 3 中, 我们将用户人数固定为 50, 感知轮次固定为 20, 而将预算从 1000 逐步增加值 11000. 在设定 4 中, 用户的人数从 5 升至 100, 同时预算设置为人数的 50 倍. 在设定 5 中, 轮次从 5 增加至 100, 同时预算设置为轮次的 200 倍. 默认的人数和轮次分别设定为 50 和 20. 常数 ϵ 设定为 0.5. 我们将 5 种不同设定的参数设置汇总为表 1.

表 1 实验设定

| 设定 | 轮次 (T) | 用户人数 (n) | 预算 (B) |
|----|------------|--------------|------------|
| 1 | 20 | 5~100 | 5000 |
| 2 | 5~100 | 50 | 5000 |
| 3 | 20 | 50 | 1000~11000 |
| 4 | 20 | 5~100 | 50 n |
| 5 | 5~100 | 50 | 200 T |


6.2 实验结果

BIM-ST 和 BIM-DY 在设定 1 中的实验结果分别展示在图 1(a) 和图 2(a) 中. 我们可以看出, 随着用户数量的增多, 总信息量也随之增加, 并最终由于预算耗尽而达到饱和状态. 同时, 我们可以观测到当用户人数较小时 (小于 30 人), 4 个算法所取得的效果


相当. 这是因为用户数量足够小时, 预算能够承担每轮选择所有用户的成本. 当用户数量增大时, 算法之间的差异开始显现, 理想情况下的完备信息算法性能优于 BIM, 而 BIM 则优于 Bdg-Greedy 和 Info-Greedy 方法.

图 1(b) 和图 2(b) 展示了在设定 2 中的实验结果. 可以观察到, 4 个算法在用户数量足够小时能够取得同样的信息量. 而当用户数量逐渐增大时, 理想情况下的完备信息算法取得最好的效果, 这是因为它拥有完备的信息而无需进行探索, 可以直接进行最优的用户选择. BIM 算法的效果好于 Bdg-Greedy 和 Info-Greedy, 这是因为 BIM 同时考虑了预算和用户的信息量. 与设定 1 不同, 设定 2 中的曲线随轮次的增加而增加, 但并不收敛. 这是因为, 当轮次增加时, 信息量子模的特性会使得我们在不增加预算的情况下, 可以将用户分配到新轮次中而不断增加信息量.


设定 3 考虑了预算对用户选择的影响, 即固定用户人数和轮次不变, 考虑不同预算对算法效果的影响. 实验结果展示在图 1(c) 和图 2(c) 中. 我们观察到, 在开始阶段, 信息量随着预算的增加而增加, 这是因为更多的预算能够使我们选择更多的用户. 而当预算足够大时, 所有用户都被选择, 这时信息量就达到饱和状态.



(a) 在不同用户人数下的表现




(b) 在不同轮次数下的表现




(c) 在不同预算下的表现


图 1 BIM-ST 在 3 种不同设定中的效果



(a) 在不同用户人数下的表现



(b) 在不同轮次数下的表现



(c) 在不同预算下的表现

图 2 BIM-DY 在 3 种不同设定中的效果

图 3 展示了 BIM-ST 和 BIM-DY 在设定 4 中的表现. 能够看出, 算法取得的信息量随着用户人数的增加而增加. 这是因为更多的预算允许我们去选择更多的用户. 我们同时观察到, 随着用户人数的增加, 信息量的增速逐渐放缓. 比如用户人数为 50 时我们所取得的信息量超过 300, 而当用户人数达到 100 时所取得的信息量不超过 500. 这是由于信息量子模特性所导致的. 同时, BIM-ST 和 BIM-DY 都达到远胜于两种贪心选择算法的效果, 同时接近完备信息下的算法.

图 4 展示了在设定 5 中的实验效果. 能够看出,


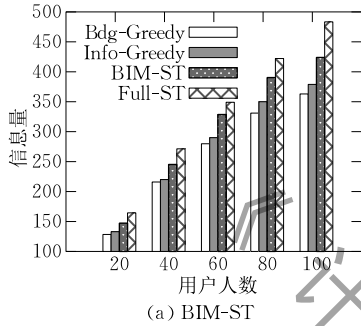


图 3 BIM-ST 和 BIM-DY 在第 4 种设定中的效果

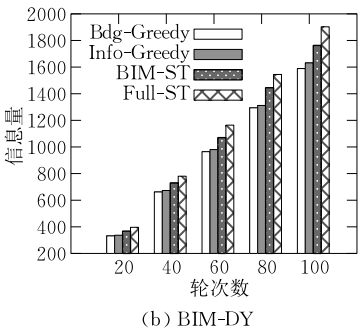
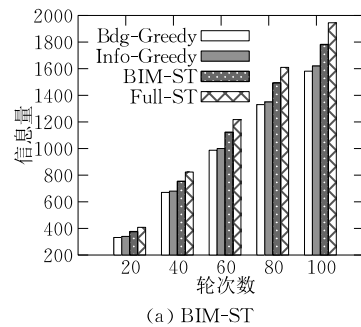


图 4 BIM-ST 和 BIM-DY 在第 5 种设定中的效果

所取得的信息量与轮次几乎呈线性关系. 这是因为, 在预算是轮次 200 倍的情况下, 算法持续选择新增轮次下的最好用户, 所取得的信息量将会与轮次数呈近似线性关系. 此外, 我们也可以看出, 我们所提出的多臂老虎机算法 BIM-ST 和 BIM-DY 也取得了和完备信息算法接近的效果.

7 总结

本文考虑了群智感知网络中有预算限制条件下的信息量最大化用户选择问题. 我们提出了一种基于互信息的信息量衡量指标, 首先考虑了用户选择成本已知的理想情况, 并提出了一个近似最优的多轮用户选择算法, 能够达到 $(1-1/e)/2$ 的近似比. 而后, 我们考虑缺失用户选择成本先验知识的实际情况, 并提出了两个多臂老虎机算法 BIM-ST 和 BIM-DY, 它们分别应对静态和动态的用户移动场景. 实验结果显示, 我们所提出的多臂老虎机算法能够有效地利用预算, 取得近似最优的信息量值. 在后续的研究中, 我们计划对用户的异质性、环境信息的时间相关性等进行深入研究, 探讨它们对总信息量的影响.

参 考 文 献

- [1] Ganti M, Ye F, Lei F. Mobile crowdsensing: Current state and future challenges. *IEEE Communications Magazine*, 2011, 49(11): 32-39
- [2] Azizyan M, Constandache I, Choudhury R R. SurroundSense: Mobile phone localization via ambience fingerprinting// *Proceedings of the 15th Annual International Conference on Mobile Computing and Networking*. Beijing, China, 2009: 261-272
- [3] Rai A, Chintalapudi K K, et al. Zee: Zero-effort crowdsourcing for indoor localization// *Proceedings of the 18th Annual International Conference on Mobile Computing and Networking*. Istanbul, Turkey, 2012: 293-304
- [4] Dutta P, Aoki P M, et al. Common sense: Participatory urban sensing using a network of handheld air quality monitors // *Proceedings of the 7th ACM Conference on Embedded Networked Sensor Systems*. Berkeley, USA, 2009: 349-350
- [5] Zhou P, Zheng Y, Li M. How long to wait?: Predicting bus arrival time with mobile phone based participatory sensing// *Proceedings of the 10th International Conference on Mobile Systems, Applications, and Services*. Lake District, UK, 2012: 379-392
- [6] Nawaz S, Efstathiou C, Mascolo C. ParkSense: A smartphone based sensing system for on-street parking// *Proceedings of the 19th Annual International Conference on Mobile Computing & Networking*. Miami, USA, 2013: 75-86

- [7] Gao R, Zhao M, et al. Jigsaw: Indoor floor plan reconstruction via mobile crowdsensing//Proceedings of the 20th Annual International Conference on Mobile Computing and Networking. Hawaii, USA, 2014: 249-260
- [8] Cressie N. Statistics for Spatial Data. John Wiley & Sons, 1991
- [9] Deshpande A, Guestrin C, et al. Model-driven data acquisition in sensor networks//Proceedings of the 30th International Conference on Very Large Data Bases, VLDB Endowment. Toronto, Canada, 2004: 588-599
- [10] Singer Y. Budget feasible mechanisms//Proceedings of the 51st Annual IEEE Symposium on Foundations of Computer Science. Las Vegas, USA, 2010: 765-774
- [11] Zhao D, Li X-Y, Ma H. How to crowdsource tasks truthfully without sacrificing utility: Online incentive mechanisms with budget constraint//Proceedings of the 2014 IEEE Conference on Computer Communications. Toronto, Canada, 2014: 1213-1221
- [12] Lee J-S, Hoh B. Sell your experiences: A market mechanism based incentive for participatory sensing//Proceedings of the IEEE International Conference on Pervasive Computing and Communications. Mannheim, Germany, 2010: 60-68
- [13] Yang D, Xue G, et al. Crowdsourcing to smartphones: Incentive mechanism design for mobile phone sensing//Proceedings of the 18th Annual International Conference on Mobile Computing and Networking. Istanbul, Turkey, 2012: 173-184
- [14] Yang S, Wu F, et al. On designing data quality-aware truth estimation and surplus sharing method for mobile crowdsensing. IEEE Journal on Selected Areas in Communications, 2017, 35(4): 832-847
- [15] Yang S, Wu F, Tang S, et al. Good work deserves good pay: A quality-based surplus sharing method for participatory sensing//Proceedings of the 44th International Conference on Parallel Processing. Beijing, China, 2015: 380-389
- [16] Dong M, Lan T, Zhong L. Rethinking energy accounting with cooperative game theory//Proceedings of the 20th Annual International Conference on Mobile Computing and Networking. Hawaii, USA, 2014: 531-542
- [17] Jiawei H, Kamber M. Data Mining: Concepts and Techniques. Morgan Kaufmann, Waltham, USA, 2001
- [18] Yang S, Han K, Zheng Z, et al. Towards personalized task matching in mobile crowdsensing via fine-grained user profiling //Proceedings of the 2018 IEEE Conference on Computer Communications. Honolulu, USA, 2018: 2411-2419
- [19] Poduri S, Sukhatme G S. Constrained coverage for mobile sensor networks//Proceedings of the 2004 International Conference in Robotics and Automation. New Orleans, USA, 2004: 165-171
- [20] Guestrin C, Krause A, Singh A P. Near-optimal sensor placements in Gaussian processes//Proceedings of the 22nd International Conference on Machine Learning. Bonn, Germany, 2005: 265-272
- [21] Krause A, Guestrin C, et al. Near-optimal sensor placements: Maximizing information while minimizing communication cost//Proceedings of the 5th International Conference on Information Processing in Sensor Networks. Nashville, USA, 2006: 2-10
- [22] Cover T M, Thomas J A. Elements of Information Theory. Hoboken, New Jersey, USA: John Wiley & Sons, 2012
- [23] Ramakrishnan N, Bailey-Kellogg C, et al. Gaussian processes for active data mining of spatial aggregates//Proceedings of the 2005 SIAM International Conference on Data Mining. Newport Beach, USA, 2005: 427-438
- [24] Peng H, Long F, Ding C. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238
- [25] Peng D, Wu F, Chen G. Pay as how well you do: A quality-based incentive mechanism for crowdsensing//Proceedings of the 16th International Symposium on Mobile Ad Hoc Networking on Computing. Hangzhou, China, 2015: 177-186
- [26] Vermorel J, Mohri M. Multi-armed bandit algorithms and empirical evaluations//Proceedings of the European Conference on Machine Learning. Berlin, Germany, 2005: 437-448
- [27] Robbins H. Some aspects of the sequential design of experiments. Bulletin of the American Mathematical Society, 1952, 58(5): 527-535
- [28] Auer P, Cesa-Bianchi N, Fischer P. Finite-time analysis of the multiarmed bandit problem. Machine Learning, 2002, 47(2-3): 235-256
- [29] Tran-Thanh L, Chapman A, et al. Epsilon-first policies for budget-limited multi-armed bandits//Proceedings of the AAAI Conference on Artificial Intelligence. Atlanta, USA, 2010: 1214-1216
- [30] Tran-Thanh L, Stein S, et al. Efficient crowdsourcing of unknown experts using multi-armed bandits. Artificial Intelligence, 2014, 214: 89-111
- [31] Tran-Thanh L, Chapman A, et al. Knapsack based optimal policies for budget-limited multi-armed bandits//Proceedings of the AAAI Conference on Artificial Intelligence. Toronto, Canada, 2012: 1134-1140
- [32] Ho C J, Vaughan J W. Online task assignment in crowdsourcing markets//Proceedings of the AAAI Conference on Artificial Intelligence. Toronto, Canada, 2012: 45-51
- [33] Ding W, Qin T, et al. Multi-armed bandit with budget constraint and variable costs//Proceedings of the AAAI Conference on Artificial Intelligence. Bellevue, Washington, USA, 2013: 232-238
- [34] Chen W, Wang Y, Yuan Y. Combinatorial multi-armed bandit: General framework and applications//Proceedings of the International Conference on Machine Learning. Atlanta, USA, 2013: 151-159
- [35] Singla A, Krause A. Truthful incentives in crowdsourcing tasks using regret minimization mechanisms//Proceedings of the 22nd International Conference on World Wide Web. Rio de Janeiro, Brazil, 2013: 1167-1178

- [36] Biswas A, Jain S, et al. A truthful budget feasible multi-armed bandit mechanism for crowdsourcing time critical tasks//Proceedings of the 2015 International Conference on Autonomous Agents and Multiagent Systems. Istanbul, Turkey, 2015; 1101-1109
- [37] McCullough J C, Agarwal Y, et al. Evaluating the effectiveness of model-based power characterization//Proceedings of the USENIX Annual Technical Conference. Boston, USA, 2011; 1-14
- [38] Babaiouff M, Sharma Y, Slivkins A. Characterizing truthful multi-armed bandit mechanisms//Proceedings of the 10th ACM Conference on Electronic Commerce. Stanford, USA, 2009; 79-88
- [39] Devanur N R, Kakade S M. The price of truthfulness for pay-per-click auctions//Proceedings of the 10th ACM Conference on Electronic Commerce. Stanford, USA, 2009; 99-106
- [40] Liao W, Ji Q, Wallace W. Approximate nonmyopic sensor selection via submodularity and partitioning. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 2009, 39(4): 782-794
- [41] Khuller S, Moss A, Naor J S. The budgeted maximum coverage problem. *Information Processing Letters*, 1999, 70(1): 39-45
- [42] Krause A, Golovin D. *Submodular Function Maximization. Tractability: Practical Approaches to Hard Problems*. Cambridge, UK: Cambridge University Press, 2014, 71: 104
- [43] Liu J, Shen H, Narman H S, et al. A survey of mobile crowdsensing techniques: A critical component for the Internet of Things. *ACM Transactions on Cyber-Physical Systems*, 2018, 2(3): 18
- [44] Huang K L, Kanhere S S, Hu W. On the need for a reputation system in mobile phone based sensing. *Ad Hoc Networks*, 2014, 12: 130-149
- [45] Jin H, Su L, et al. Quality of information aware incentive mechanisms for mobile crowd sensing systems//Proceedings of the 16th ACM International Symposium on Mobile Ad Hoc Networking and Computing. Hangzhou, China, 2015; 167-176
- [46] Lin J, Yang D, Li M, et al. Frameworks for privacy-preserving mobile crowdsensing incentive mechanisms. *IEEE Transactions on Mobile Computing*, 2018, 17(8): 1851-1864
- [47] Wang X, Jia R, Tian X, et al. Dynamic task assignment in crowdsensing with location awareness and location diversity //Proceedings of the IEEE Conference on Computer Communications. Honolulu, USA, 2018; 2420-2428
- [48] Restuccia F, Ferraro P, Silvestri S, et al. IncentMe: Effective mechanism design to stimulate crowdsensing participants with uncertain mobility. *IEEE Transactions on Mobile Computing*, 2018, 18(7): 1571-1584
- [49] Auer P, Cesa-Bianchi N, et al. The non-stochastic multiarmed bandit problem. *SIAM Journal on Computing*, 2002, 32(1): 48-77
- [50] Tekin C, Liu Mingyan. Online algorithms for the multi-armed bandit problem with Markovian rewards//Proceedings of the 48th Annual Allerton Conference on Communication, Control, and Computing. Allerton, USA, 2010; 1675-1682
- [51] Bubeck S, Cesa-Bianchi N. Regret analysis of stochastic and nonstochastic multi-armed bandit problems. *Foundations and Trends in Machine Learning*, 2012, 5(1): 1-122
- [52] Li L, Chu W, Langford J, Schapire R E. A contextual-bandit approach to personalized news article recommendation//Proceedings of the 19th International Conference on World Wide Web. Raleigh, USA, 2010; 661-670
- [53] Yang S, Qi X, Wu F, et al. Bandit user selection algorithm for budgeted and time-limited mobile crowdsensing//Proceedings of the 2017 IEEE Global Communications Conference. Singapore, 2017; 1-6
- [54] Yang S, Wu F, et al. Selecting most informative contributors with unknown costs for budgeted crowdsensing//Proceedings of the 24th International Symposium on Quality of Service. Beijing, China, 2016; 1-6



YANG Shuo, Ph.D.. His research interests include mobile computing and wireless networking.

WU Fan, Ph.D., professor. His research interests include network economics, wireless networking, mobile computing, and privacy security.

CHEN Gui-Hai, Ph.D., professor. His research interests include distributed computing, computer networks, and parallel computing.

Background

Mobile crowdsensing has become a hot topic in ubiquitous computing and mobile computing. Numerous real applications can adopt mobile computing to fulfill their needs of local data collection and sharing. It has also been extensively studied

from the theoretical perspectives, such as designing appropriate mechanisms to encourage users' long-term participation, designing efficient user selection strategies to optimize certain utility metric, and measuring the data quality of collected data.

However, studies on how to select users so as to minimize the redundant information collected are missing. In this work, we tend to fill this gap by considering selecting most informative users. This is an important and emerging topic in real mobile crowdsensing scenarios, especially when the platform has only a limited budget to select users.

In this work, we model this budgeted informative user selection into a constrained optimization problem. The objective is to maximize the obtained informativeness, which is characterized by a proposed mutual information-based metric. The constraint is that total payments of the selected users cannot exceed a given budget. The problem is NP-hard. To address the NP-hardness of the problem, we propose an efficient single-rounded user selection algorithm with a constant approximation ratio, and extend the single-rounded algorithm to multi-rounded scenario with the same approximation ratio. Furthermore, we consider a more challenging problem where the cost for each user is unknown a priori. In

this case, we need to learn the users' costs and make decision in an online manner. We model the problem as a multi-armed bandit problem with stochastic assumptions, and propose multi-armed bandit algorithms for both static and dynamic scenarios, respectively. Both theoretical and experimental results demonstrate that our algorithm can effectively utilize the budget to select most informative users, dramatically improving the total informativeness obtained compared with our benchmarks.

This work is supported in part by the National Key Research and Development Program "Cloud Computing and Big Data" (No. 2018YFB1004703), and in part by the National Natural Science Foundation (Nos. 61672353, 61672348). The opinions, findings, conclusions, and recommendations expressed in this paper are those of the authors and do not necessarily reflect the views of the funding agencies or the government.