

基于综合评分的移动群智感知隐私激励机制

傅彦铭, 张思远

引用本文

傅彦铭, 张思远. 基于综合评分的移动群智感知隐私激励机制[J]. 计算机科学, 2024, 51(7): 397-404.

FU Yanming, ZHANG Siyuan. [Privacy Incentive Mechanism for Mobile Crowd-sensing with Comprehensive Scoring](#) [J]. Computer Science, 2024, 51(7): 397-404.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向公平性联邦学习的指纹识别算法](#)

Study on Fingerprint Recognition Algorithm for Fairness in Federated Learning

计算机科学, 2024, 51(6A): 230800043-9. <https://doi.org/10.11896/jsjcx.230800043>

[基于知识蒸馏的差分隐私联邦学习方法](#)

Differential Privacy Federated Learning Method Based on Knowledge Distillation

计算机科学, 2024, 51(6A): 230600002-8. <https://doi.org/10.11896/jsjcx.230600002>

[基于差分隐私的联邦学习方案](#)

Federated Learning Scheme Based on Differential Privacy

计算机科学, 2024, 51(6A): 230600211-6. <https://doi.org/10.11896/jsjcx.230600211>

[边缘计算下差分隐私的应用研究综述](#)

Survey of Application of Differential Privacy in Edge Computing

计算机科学, 2024, 51(6A): 230700089-9. <https://doi.org/10.11896/jsjcx.230700089>

[基于区块链的可搜索属性加密技术应用综述](#)

Survey on Application of Searchable Attribute-based Encryption Technology Based on Blockchain

计算机科学, 2024, 51(6A): 230800016-14. <https://doi.org/10.11896/jsjcx.230800016>

基于综合评分的移动群智感知隐私激励机制

傅彦铭 张思远

广西大学计算机与电子信息学院 南宁 530004

(fym2005@126.com)

摘要 移动群智感知系统(MCS)能否高效地运行,很大程度上取决于是否有大量任务参与者参与到感知任务中。然而在现实中,用户的感知成本增加以及用户的隐私泄露等原因,导致用户的参与积极性不高,因此需要一种有效的手段,用于在保证用户隐私安全的同时,还能促进用户积极地参与到任务中。针对上述问题,结合本地化差分隐私保护技术,提出了一种基于综合评分的双边拍卖隐私激励机制(Privacy Incentive Mechanism of Bilateral Auction with Comprehensive Scoring,BCS),这种激励机制包括拍卖机制、数据扰动和聚合机制以及奖励和惩罚机制3个部分。拍卖机制综合考虑了各种因素对用户完成感知任务的影响,在一定程度上提高了任务的匹配程度;数据扰动和聚合机制在隐私保护和数据精度之间做出权衡,在保证数据质量的同时做到了对用户隐私的良好保护;奖励和惩罚机制奖励诚信度和活跃度高的用户,激励用户积极参与感知任务。实验结果表明,BCS可以在提高平台收益和任务匹配率的同时保证感知数据的质量。

关键词 移动群智感知;激励机制;隐私保护;综合评分;数据扰动和聚合

中图分类号 TP391

Privacy Incentive Mechanism for Mobile Crowd-sensing with Comprehensive Scoring

FU Yanming and ZHANG Siyuan

School of Computer, Electronics and Information, Guangxi University, Nanning 530004, China

Abstract The efficient operation of mobile crowd-sensing(MCS) largely depends on whether a large number of users participate in the sensing tasks. However, in reality, due to the increase of user's sensing cost and the privacy disclosure of users, the users' participation enthusiasm is not high, so an effective mean is needed to ensure the privacy security of users, and it can also promote users to actively participate in the tasks. In response to the above issues, a new privacy incentive mechanism of bilateral auction with comprehensive scoring(BCS) based on local differential privacy protection technology is proposed. This incentive mechanism includes three parts: auction mechanism, data perturbation and aggregation mechanism, and reward and punishment mechanism. The auction mechanism comprehensively considers the impact of various factors on users' sensing tasks, to some extent, it improves the matching degree of tasks. The data perturbation and aggregation mechanism makes a balance between privacy protection and data accuracy, and achieves good protection of user privacy while ensuring data quality. The reward and punishment mechanism rewards users of high integrity and activity to encourage users to actively participate in sensing tasks. Experimental results indicate that BCS can improve platform revenue and task matching rate while ensuring the quality of sensing data.

Keywords Mobile crowd-sensing, Incentive mechanism, Privacy protection, Comprehensive scoring, Data perturbation and aggregation

1 引言

移动群智感知(MCS)^[1]随着移动电子设备的激增和智能城市的发展而产生,并得到了快速发展。与无线传感网络不同,移动群智感知的数据收集工作依赖拥有感知功能的智能设备的移动用户进行,是一种新的感知模式。目前,移动群智感知已经在取得广泛的应用,如环境检测^[2]、交通检测^[3]等。然而,执行传感任务不仅要花费用户的时间和精力,而且还要承担隐私泄露的风险,因为传感数据可能包含用户的

敏感信息。因此,如何激励用户执行传感任务是一项具有挑战性的任务。本地化差分隐私保护机制^[4]是群智感知隐私保护研究中最常用的隐私保护模型,在群智感知隐私保护问题研究领域得到了广泛的应用,它允许用户根据自己的隐私预算在原始感知数据中添加噪声,个性化地保护自己的隐私^[5]。

为了激励用户积极参与感知任务并上传高质量数据,本文结合本地化差分隐私保护机制提出了BCS激励机制,这种机制包括拍卖机制、数据扰动和聚合机制以及奖励和惩罚机制3个部分。拍卖机制以双边拍卖^[6]为模型进行建模,系统

到稿日期:2023-04-24 返修日期:2023-07-20

基金项目:国家自然科学基金(61962005)

This work was supported by the National Natural Science Foundation of China(61962005).

通信作者:张思远(1elandsy28@163.com)

除了关心用户对想要完成任务的竞价之外,还关心用户在执行感知任务时是否更加积极,数据质量是否符合要求,即用户的活跃度和诚信度,以用户的活跃度和诚信度进行综合评分,可以得到执行任务的高质量用户,提高任务的匹配率。在用户执行完所分配的任务并汇报结果时,由于对用户进行隐私保护,用户的数据质量会受到影响,本文使用基于权重的数据聚合方法^[7]来对经过本地化差分隐私技术扰动的数据进行重组,并将其返回给任务发布者。任务发布者在得到想要的任务结果后,会向参与任务的用户支付报酬,同时系统会根据此任务的完成情况,来判断哪些用户参与任务的积极性更高,以得到更好的数据。此时的奖励和惩罚机制会奖励诚信度和活跃度高的用户,以激励用户积极参与感知任务,如果用户的诚信度或活跃度太低还会被系统拉入黑名单,禁止用户参与任务竞拍。BCS系统模型如图1所示。

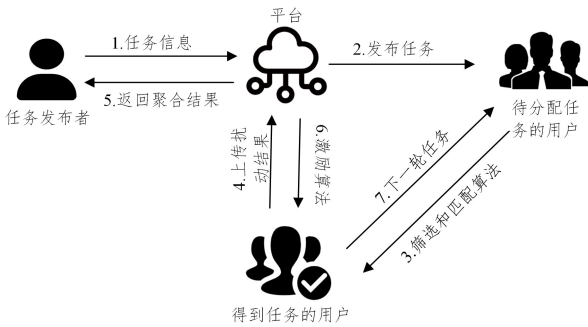


图1 BCS系统模型

Fig. 1 BCS system model

2 相关工作

激励机制的设计是群智感知领域的重点研究方向之一,根据鼓励用户参与的奖励类型,可以将激励机制分为货币激励和非货币激励两类^[8]。非货币激励允许用户自愿参与研究项目,否则会由于执行成本过高而不可能实现这些项目,非货币激励的奖励来自于与社交关系网络中的其他成员的互动,如娱乐游戏、声誉、社会关系激励^[9-10]。货币激励主要分为货币静态激励和货币动态激励^[11],在货币静态激励中,奖励的数量是通过某种标准预先确定的,且在整个实验中该数量是相同的。Mushag等^[12]以小额支付的形式使用了3种静态奖励,即统一、可变和隐藏,每种激励方案都留住了大约62%的参与者。货币动态激励为每个任务设定可变预算,但是预算取决于系统的实时条件,因此更符合设计情况,货币动态激励常用的方法是基于博弈论的拍卖机制,主要包括正向拍卖、逆向拍卖和双向拍卖^[13-15]。Ji等^[16]提出了一种基于逆向拍卖的激励机制(RAIN),该机制在招聘新员工、执行逆向拍卖和留住现有员工时考虑了参与者的潜在贡献,优化了系统中的工人组成,同时降低了系统成本。Zhang等^[17]提出了一种真实和最优的双向拍卖机制,以获取用户和任务的私有信息,同时实现与信息对称下相同的最优分配。

隐私保护也是群智感知研究领域最常见的问题,隐私保护常见的方法有数据失真、加密以及访问控制3种。本地化差分隐私保护技术由Dwork^[18]于2006年提出,其基于数据失真方法,不依赖于攻击者的背景知识,从根本上解决了传统方法难以对攻击模型做出合理假设,从而导致用户隐私仍然

存在较大泄露风险的问题。有许多研究基于本地化差分隐私保护技术展开,Wang等^[19]针对移动群智感知中参与者的位置隐私问题,提出了一种基于局部差分隐私偏好的参与者位置保护方法,通过仿真实验证明了地图密度分割可以降低隐私成本。Li等^[20]提出了一种基于基本RAPPOR的具有最优隐私扰动参数的LDP算法,通过最小化期望均方误差(EMSE)来提高数据效用。

在现有的研究中,虽然有很多关于激励机制和隐私保护的改进与探索,但是很少有综合两种问题的研究,大多数的研究都是从如何鼓励用户参与感知任务或者如何保护用户的隐私这种单一角度提出问题并给出解决方案的,但是在实际的生产活动中,这两类问题往往交织在一起,因此需要从两个维度综合思考问题。如何鼓励用户在积极参与感知任务的同时保证用户的隐私安全,用户的隐私安全得到保证以后但是感知数据质量下降怎么办,是本文要讨论的关键问题。针对上述问题,本文提出了一种基于综合评分的移动群智感知隐私激励机制(BCS),与现有工作相比,本文方法有以下改进。

1)由于用户的活跃度代表了用户参与任务的积极性,用户的诚信度代表了用户是否能够保证执行感知任务的质量,因此以用户的活跃度和诚信度为考评依据选择高质量的用户,抓住了主要矛盾,将用户与任务不匹配的问题在任务分配阶段进行解决,筛选出更多高质量的用户参与感知任务,在一定程度上提高了任务的匹配率。

2)将隐私保护问题融入激励问题的研究中,因为在执行任务的过程中用户的隐私泄露也是用户参与任务积极性不高的主要原因之一,所以本文采用本地化差分隐私保护机制,将隐私保护的过程交还给用户,使用户可以根据隐私预算的大小来动态地保护自身隐私。

3)针对用户隐私安全得到保证之后造成的感知数据质量下降的问题,结合基于权重的数据聚合方法,根据用户的可靠度为用户分配不同的权重,那么最终聚合得到的感知数据结果会靠近可靠度高的用户提供的感知数据,从而保证感知数据的质量。

3 系统建模和模型定义

3.1 系统建模

用户、任务发布者和平台之间的互动是实现大规模感知任务的关键。我们根据双边拍卖模型对三者之间的交互进行建模,假设任务发布者在平台上发布了 N 个感知任务 $T = \{T_1, T_2, \dots, T_N\}$,平台上现有注册用户 M 个,表示为 $W = \{W_1, W_2, \dots, W_M\}$,系统的流程表示为:

1)任务发布者提交感知任务到平台上,平台收到任务后对任务进行初始化,然后将任务和相关的要求广播给 M 个用户。

2)拍卖机制。用户收到平台发布的任务之后,向平台上传想要执行的任务报价集合 $B = \{b_{1,1}, b_{1,2}, \dots, b_{1,j}, b_{i,j}\}$,表示用户 W_i 执行感知任务 T_j 的竞价,其中包含了所需要花费的隐私成本和感知成本。平台在收到竞价信息以后,结合筛选算法和匹配算法给用户分配任务,并给出合理的定价。

3)数据扰动和聚合机制。获胜的用户得到感知任务 T_j 以后执行得到感知结果 $O_{i,j}$,对感知结果 $O_{i,j}$ 进行一定的扰动

得到 $\hat{O}_{i,j}$,并将其上传到平台。平台收到任务扰动结果以后,根据数据聚合机制得到聚合结果 O_i ,将结果返回给任务发布者,并给予执行此任务的用户一定的报酬。

4)奖励和惩罚机制。平台对用户的活跃度和诚信度进行更新,奖励活跃度和诚信度高的用户,使其在下次参与任务拍卖时更有优势。

3.2 模型定义

本节主要讲述系统拍卖模型的指标定义。

定义 1(用户执行任务的总成本) 对于任务 T_j 来说,用户执行该任务的成本主要来自两方面,一方面在执行任务的过程中会产生自身的损耗,表现为感知成本 $c_{i,j}^s$;另一方面,用户在上传感知结果的过程中会产生隐私泄露的问题,且与自身的隐私预算有关,表现为隐私成本 $c_{i,j}^p \in \epsilon_{i,j}$ 。因此用户 W_i 执行任务 T_j 的成本可以表示为 $c_{i,j} = c_{i,j}^s + c_{i,j}^p \in \epsilon_{i,j}$, $c_{i,j}$ 表示执行任务总成本。

定义 2(平台总支付) 对于任务参与者 W_i ,当感知任务完成以后,平台会对其支付报酬 $p_{i,j}$,一个用户获得的总报酬为用户完成所有任务的报酬之和 $p_i = \sum_{T_j \in T_w} p_{i,j}$,平台的总支出即为所有任务参与者完成任务所获取的总报酬 $P = \sum_{W_i \in W_w} p_i$ 。

定义 3(平台效用) 对于平台来说,平台的收益主要来自将任务发布者支付的总费用支付给用户以后赚取的差价,因此这个差价越高,说明平台的效益越好。平台效用的表达式如下:

$$U = \sum_{W_i \in W_w} \sum_{T_j \in T_w} q_{i,j} - \sum_{W_i \in W_w} \sum_{T_j \in T_w} p_{i,j} \quad (1)$$

其中, $q_{i,j}$ 表示 W_i 完成任务 T_j 后任务发布者给予平台的费用, $p_{i,j}$ 表示 W_i 完成任务 T_j 得到的报酬。

定义 4(参与者效用) 每个参与者的效用主要表示为任务参与者获得的任务报酬和完成任务的成本之间的差值,如果 W_i 是获胜用户,则 $u_{i,j} = p_{i,j} - c_{i,j}$;否则 $u_{i,j} = 0$ 。

4 设计目标

下文主要讲述 BCS 系统需要满足的目标,包括以下 5 个部分。

定义 5(ϵ -差分隐私^[21]) 用 X_1 和 X_2 表示任意两个相邻的数据集,如果一个随机算法 M 满足 ϵ -差分隐私,则任何可能的隐私保护结果 $\mathcal{S} \subseteq \text{Range}(M)$,即可以表示为 $\Pr[M(X_1) \in \mathcal{S}] \leq \exp(\epsilon) \times \Pr[M(X_2) \in \mathcal{S}]$ 。 ϵ 是一个小正数,通常称为隐私预算。

定义 6(α - β 准确度^[7]) 对于任意两个取值范围为 $[0, 1]$ 的随机变量 Y_1 和 Y_2 ,当且仅当 $\Pr[|Y_1 - Y_2| \geq \alpha] \leq \beta$ 时, Y_1 对 Y_2 满足 α - β 准确度, $\alpha, \beta \in (0, 1)$ 且 Y_2 可以为常数。

定义 7(计算有效性) BCS 的主要算法可以在有效时间内执行完成。

定义 8(个体合理性) 对于每个参与任务的用户,其都可以获得效用 $u_{i,j} \geq 0$ 。

定义 9(真实性) 对于每个参与竞价的用户,用户不能通过虚假报价的方式增加其所得的效用 $u_{i,j}$ 。

5 BCS 设计细节

5.1 综合评分机制设计细节

本文设计了一种综合评分机制,综合考虑用户的诚信度

和活跃度因素,最终为潜在用户评出综合得分 $s_{i,j}$ 。 $s_{i,j}$ 的值越大,潜在用户越容易成为获胜的用户。这些综合因素在用户执行任务的过程中都发挥了重要作用,对于名声差、不活跃的用户,我们会将其标记为劣质用户,以减少其获得任务的机会。

5.1.1 诚信度因素和奖惩机制

本文中,用户的诚信度和用户的可靠度息息相关,用户的可靠度是任务感知结果 $O_{i,j}$ 和其上传的感知结果 $\hat{O}_{i,j}$ 的绝对误差的数学期望,表达式为:

$$\theta_{i,j} = E[|\hat{O}_{i,j} - O_{i,j}|] \in [0, 1] \quad (2)$$

给出用户可靠度 $\theta_{i,j}$ 的定义之后,即可定义用户诚信度 $h_{i,j}$ 的计算。本文在满足用户隐私预算的前提下,设计用户提交数据的噪声分布,使得用户噪声的总和服从拉普拉斯分布^[22]。我们可以认为用户可靠度为所添加噪声的绝对值 $|n_{i,j}|$,据此写出计算用户可靠度的表达式:

$$\theta_{i,j} = |n_{i,j}| \quad (3)$$

诚信度因素的奖励和惩罚机制有利于挑选优质的用户参与感知任务,通过提高优质用户的诚信度值,降低劣质用户的诚信度值,可以让优质的用户在分配任务的过程中更有优势,从而激励更多优质用户参与到感知任务中,以更好地完成任务。用户的诚信度更新函数如下^[23]:

$$h_{i,j} = \begin{cases} h_{i,j-1} + \varphi(1 - \theta_{i,j}), & \theta_{i,j} - \bar{n}_j \leq 0 \\ h_{i,j-1} + \varphi \ln(1 - \theta_{i,j})^2, & \theta_{i,j} - \bar{n}_j > 0 \end{cases} \quad (4)$$

其中, φ 为奖惩系数, \bar{n}_j 表示所有参与任务 T_j 的用户所添加的噪声均值, $\theta_{i,j}$ 为用户可靠度, $h_{i,j}$ 表示用户 W_i 对任务 T_j 更新后的诚信度值, $h_{i,j-1}$ 表示用户 W_i 对任务 T_j 的历史诚信度值。

5.1.2 活跃度因素和奖惩机制

用户的活跃度表示用户能否积极地完成感知任务,一般来说,越积极的用户对任务有着越大的贡献价值,因此本文将用户的活跃度列为选择任务参与者的参考指标之一。将平台发布任务的时间作为开始时间,在用户完成任务以后,记录用户把感知结果上传至平台的时间,作为任务结束时间,可以得到所有参与完成任务 T_j 的用户的平均完成时间和每个用户各自的任务完成时间,根据两个完成时间,可以更新用户 W_i 对任务 T_j 的活跃度,用户活跃度更新函数表示为:

$$a_{i,j} = \begin{cases} a_{i,j-1} + \rho * e^{-\frac{|t_{i,j} - \bar{t}_{i,j}|}{t_{\max} - t_{\min}}}, & t_{i,j} \leq \bar{t}_j \\ a_{i,j-1} - \rho * e^{-\frac{|t_{i,j} - \bar{t}_{i,j}|}{t_{\max} - t_{\min}}}, & t_{i,j} > \bar{t}_j \end{cases} \quad (5)$$

其中, $a_{i,j}$ 表示用户 W_i 对任务 T_j 更新后的活跃度值, $a_{i,j-1}$ 表示用户 W_i 对任务 T_j 的历史活跃度值, $t_{i,j}$ 是此用户完成任务 T_j 的时间, $\bar{t}_{i,j}$ 是所有参与 T_j 的用户的平均完成时间, t_{\max} 是 T_j 的最大完成时间, t_{\min} 是 T_j 的最小完成时间, ρ 是奖惩系数。

图 2 给出了可靠度与诚信度的关系函数,从图中可以观察到,用户的可靠度越小,其诚信度的增量就越大,减小量就越小,并且随着可靠度的增加,诚信度的减少量大于其增加量,减少的速度也越来越快。这样设计的目的在于用户越不诚信,惩罚力度就越大,同时也比较符合常识,人们积累信任的难度往往大于他们失去信任的难度。




图2 可靠性与诚信度之间的关系

Fig. 2 Relationship between reliability and integrity

图3给出了时间范围 $t = (t_{i,j} - \bar{t}_{i,j}) / (t_{\max} - t_{\min})$ 与活跃度之间的关系,从图中可以观察到,若用户的完成时间早于平均完成时间,即完成速度较快,则用户将获得奖励;反之,若用户的完成时间晚于平均完成时间,即完成速度较慢,则将受到惩罚。此外,惩罚力度大于奖励力度,这样设计的目的是淘汰不积极的用户。以平均完成时间为标准,可以减少如任务难度等其他客观因素带来的影响。




图3 时间范围与活跃度之间的关系

Fig. 3 Relationship between time range and activity

根据诚信度和活跃度的函数图像可知,两者的取值范围为 $[0, 1]$ 才能发挥最大作用,超过这个范围则有可能导致算法错误,而且数学中的任何值在理论上都能通过合适的方式归一化,因此本文实验中将感知数据结果和扰动结果均设置在 $[0, 1]$ 之间。本文将用户的可靠度表示为任务感知结果 $O_{i,j}$ 和其扰动结果 $\hat{O}_{i,j}$ 的绝对误差的数学期望, $O_{i,j}$ 和 $\hat{O}_{i,j}$ 两者差的绝对值就是噪声的绝对值。每个噪声的绝对值都是一个具体数值,相当于一个常数,在数学上,常数的期望仍是它本身,因此式(3)成立。

5.1.3 综合评分

本文根据用户的诚信度和用户的活跃度对用户进行综合评分,来判断此用户是否值得平台的托付。采用对用户的诚信度和活跃度赋权重的方式,动态地提高某种因素在分数中的占比。这种打分方式的好处是,如果平台更看重用户的诚信度,那么相应减少活跃度因素在打分中的比重,这不仅可以选诚信度较好的用户,还可以选择一定程度上积极的用户,有利于提升所选任务参与者的质量,进而帮助平台获得更好的感知结果,提升效率。打分的表达式如下:

$$s_{i,j} = \gamma \cdot h_{i,j} + (1 - \gamma) \cdot a_{i,j} \quad (6)$$

其中, $s_{i,j}$ 表示用户 W_i 对于任务 T_j 的综合得分, γ 表示权重系数, $h_{i,j}$ 表示用户的诚信度, $a_{i,j}$ 表示用户的活跃度。

5.2 拍卖算法的设计细节

拍卖模型的算法包括筛选算法和匹配算法两个部分,筛选算法主要用来挑选出候选任务和用户集合;匹配算法首先对每个候选任务的候选用户进行综合评价,给出评分,然后以

评分为依据,挑选合适的用户执行任务。下面详细介绍拍卖模型的筛选算法和匹配算法。

5.2.1 筛选算法

筛选算法的中心思想是每次挑选任务价值最高的任务加入候选执行任务集 T_s ,每次挑选竞价小于任务发布者给出的任务的价值 v_j 的用户,加入候选用户集合 W_s ,直到所有的任务组成候选执行任务集合 T_s 时结束循环。算法在任务集合 T 不为空时执行,第3行是挑选任务价值最高的任务,算法首先统计当前任务发布者给出的每个任务的价值,然后得到价值 v_j 最高的任务 T_j ;第4行是找到所有选择待执行任务 T_j 且竞价 $b_{i,j}$ 小于等于任务发布者给出的任务价值 v_j 的用户,以组成任务 T_j 的候选用户集合 R_j ;如果 R_j 为空,表示没有任务参与者愿意选择该任务 T_j ,将其从 T 中删除掉,反之将 T_j 加入候选执行任务集合 T_s ,将 R_j 加入 W_s ,并将 T_j 从 T 中删除(见第5-11行)。在整个算法结束后可以输出获胜的候选用户集合 W_s 和候选任务集合 T_s 。具体过程如算法1所示。

算法1 筛选算法

输入: T, W

输出: W_s, T_s

1. 初始化 W_s, T_s 为 \emptyset
2. while $|T| \neq \emptyset$ do
3. $T_j \leftarrow \operatorname{argmax}_{T_j \in T} v_j$ // 选择价值最高的任务
4. $R_j = \{W_i | b_{i,j} \leq v_j\}$ // 选择报价小的用户组成任务 T_j 的候选用户集合
5. if $|R_j| = \emptyset$ then
6. 将任务 T_j 从 T 中删除
7. else
8. 将任务 T_j 加入候选执行任务集合 T_s
9. 将 R_j 加入候选任务用户集合 W_s
10. 将任务 T_j 从 T 中删除
11. end if
12. end while

5.2.2 匹配算法

匹配算法主要用来挑选合适的用户执行任务。对于每一个候选的任务 T_j ,其可对应一个候选用户集合 R_j 。算法的第2行是找出在筛选算法中得出的任务 T_j 所对应的候选用户集合 R_j ,第3行是计算出任务发布者应该给予任务 T_j 所要花费的总费用 q_j ,表示为所有执行任务 T_j 的用户的任务价值总和 $v_{|R_j|}$ 。算法第4-7行是计算任务 T_j 对应的候选用户集合 R_j 下所有用户的综合得分。算法第8行开始按照挑选标准对候选参与者 W_i 进行排序,挑选标准为:

$$\frac{b_{i,j}}{s_{i,j}} \quad (7)$$

根据排序好的 R_j ,找出满足式(8)的最大 k 值,条件如下:

$$b_{k,j} \leq \frac{S_{k,j}}{\sum_{o=1}^k s_{o,j}} \cdot D \quad (8)$$

其中, D 为价格阈值,其大小由平台确定,最小不能小于所有执行任务 T_j 的用户的竞价总和,最大不能超过执行任务 T_j 的用户的任务价值总和,目的是保证平台盈利。

得到 k 值以后,根据两种不同的情况可以计算有资格执行任务 T_j 的用户应得的报酬值 $p_{i,j}$:

$$p_{i,j} = \begin{cases} \frac{s_{i,j}}{\sum s_{i,j}} \cdot D, & k = |R_j| \\ \frac{b_{k+1,j}}{s_{k+1,j}} \cdot s_{i,j}, & 0 < k < |R_j| \end{cases} \quad (9)$$

算法结束以后,输出获胜的用户集合 W_w 和待执行的任务集合 T_w 、任务发布者花费的费用集合 Q 、用户执行任务所获得的报酬集合 P 。具体过程如算法 2 所示。

算法 2 匹配算法

输入: W_s, T_s

输出: W_w, T_w, P, Q

1. while $j \leq |T_s|$ do
2. 找出任务 T_j 在总候选用户集合 W_s 对应的候选用户集合 R_j
3. 计算任务 T_j 的总费用 $q_j = v_{|R_j|}$
4. while $i \leq |R_j|$ do
5. 根据式(6)计算用户 W_i 对 T_j 的综合得分 $s_{i,j}$
6. 将综合得分加入综合得分集合 S
7. end while
8. 将集合 R_j 中的 W_i 按照 $\frac{b_{1,j}}{s_{1,j}} \leq \frac{b_{2,j}}{s_{2,j}} \dots$ 的顺序排列
9. 找出集合 R_j 中满足 $b_{k,j} \leq \frac{s_{k,j}}{\sum_{o=1}^k s_{o,j}} \cdot D$ 的最大 k 值
10. if $k = |R_j|$ then
11. 将 R_j 中的所有用户加入到获胜的用户集合 W_w
12. 将满足条件的任务 T_j 加入到获胜的执行任务集合 T_w
13. while $i < k+1$ do
14. 根据式(9)计算 W_i 的报酬值 $p_{i,j}$
15. 将计算得到的报酬值 $p_{i,j}$ 加入到报酬值集合 P
16. end while
17. 将任务 T_j 的花费 q_j 加入到费用集合 Q 中
18. end if
19. else if $0 < k < |R_j|$ then
20. 将满足条件的任务 T_j 加入到获胜的执行任务集合 T_w
21. while $i < k+1$ do
22. 根据式(9)计算 W_i 的报酬值 $p_{i,j}$
23. 将计算得到的报酬值 $p_{i,j}$ 加入到报酬值集合 P
24. 将任务参与者 W_i 加入到获胜的用户者集合 W_w
25. end while
26. 将任务 T_j 的花费 q_j 加入到费用集合 Q 中
27. end if
28. end while

5.3 数据扰动和数据聚合机制

本文使用本地化差分隐私技术中最常用的拉普拉斯噪声机制来实现数据扰动机制。用户 W_i 对执行任务 T_j 的感知数据 $O_{i,j}$ 添加随机噪声 $n_{i,j}$ 以进行扰动,得到扰动数据 $\hat{O}_{i,j}$,即 $\hat{O}_{i,j} = O_{i,j} + n_{i,j}$,并将扰动后的结果上传到平台。

在收到任务 T_j 的扰动数据集后,系统会根据扰动数据集对感知结果进行聚合,并将聚合的结果返回给任务发布者。本文基于权重的数据聚合机制在文献[7]中已证明满足 $\alpha - \beta$ 准确性,即用户的感知数据的聚合结果 O_j 和任务真实值 O_j^* 非常接近。用户因为感知结果的质量不同而被分配不同的权重,越可靠的用户得到的权重越高,对于用户 W_i 来说,聚合结果 O_j 的表达式如下:

$$O_j = \sum_{W_i \in W_w, T_j \in T_w} \lambda_{i,j} \hat{O}_{i,j} \quad (10)$$

其中, $\lambda_{i,j} > 0$ 表示在任务 T_j 中用户 W_i 所占的权重大小,并且 $\sum_{W_i \in W_w, T_j \in T_w} \lambda_{i,j} = 1$ 。

α_j 表示平台允许任务 T_j 的最大误差, $\theta_{i,j}$ 表示用户的可靠度。由上面的结论可知,用户的可靠度 $\theta_{i,j}$ 越小越可靠,因为可靠度 $\theta_{i,j}$ 越小说明用户所添加的噪声越小,本文规定不能选择 $\theta_{i,j} \geq 0.5$ 的用户为执行任务的用户。对于任务 T_j ,用户 W_i 的权重的计算式如下:

$$\lambda_{i,j} = \frac{\alpha_j - \theta_{i,j}}{\sum_{k, W_i \in W_w, T_j \in T_w} (\alpha_j - \theta_{k,j})}, \forall W_i \in W_w, T_j \in T_w \quad (11)$$

因此,任务 T_j 的噪声总量 n_j 为:

$$n_j = \sum_{W_i \in W_w, T_j \in T_w} \lambda_{i,j} n_{i,j} = \sum_{T_j \in T_w} G_1(K, \sigma_j) - G_2(K, \sigma_j) \sim Lap(\sigma_j) \quad (12)$$

即任务 T_j 在接受数据扰动时添加的噪声总量 n_j 服从拉普拉斯噪声机制 $Lap(\sigma_j)$ 。

5.4 激励算法

本文介绍了数据扰动机制和数据聚合机制之后,结合诚信度奖惩机制和活跃度奖惩机制可以得到激励算法,算法在系统统计用户上传的感知结果时执行。该算法的目的是奖励诚信度和活跃度较高的用户,同时惩罚诚信度和活跃度较低的用户,从而激励用户更积极地参与到感知任务中。激励算法在用户上传数据时添加噪声,即使用户仍然有隐私泄露的风险,此时攻击者已经不能通过噪声准确地推测出用户的相关信息,这样就实现了对用户的隐私保护,有效地防范了攻击者的恶意攻击。激励算法需要 5 项输入,包括执行任务的用户集合 W_w 、待执行的任务集合 T_w 、用户对任务的感知结果进行扰动时添加的噪声集合 $n_{W_i \in W_w, T_j \in T_w}$ 、用户执行任务的时间集合 $t_{W_i \in W_w, T_j \in T_w}$ 、感知结果集合 $O_{W_i \in W_w, T_j \in T_w}$ 。算法对任务集合 T_w 中每个要执行的任务 T_j 进行遍历,首先统计所有执行任务 T_j 的用户所添加的噪声集合 n_j ,并对用户 W_i 执行任务 T_j 的感知数据结果 $O_{i,j}$ 进行扰动(见算法 3 中的第 3—7 行),然后根据数据聚合方法对扰动结果进行聚合得到聚合结果 O_j ,在完成聚合任务以后,对用户 W_i 的活跃度和诚信度进行更新(见算法 3 中的第 8—14 行),直到所有任务的聚合结果全部计算完毕后输出聚合结果集合 O ,至此算法结束。具体过程如算法 3 所示。

算法 3 激励算法

输入: $W_w, T_w, n_{W_i \in W_w, T_j \in T_w}, t_{W_i \in W_w, T_j \in T_w}, O_{W_i \in W_w, T_j \in T_w}$

输出: O

1. while $j \leq |T_w|$ do
2. 找出用户集合 W_w 所有执行任务 T_j 的用户组成用户集合 R_w
3. while $i \leq |R_w|$ do
4. 找出 $n_{W_i \in W_w, T_j \in T_w}$ 中用户 W_i 向任务 T_j 添加的随机噪声 $n_{i,j}$
5. 计算用户 W_i 的可靠度 $\theta_{i,j}$,并加入到可靠度集合 θ_j
6. 对用户 W_i 执行任务 T_j 的感知数据结果 $O_{i,j}$ 进行扰动
7. end while
8. 根据式(12)对任务 T_j 的感知数据的扰动结果进行聚合
9. 计算任务 T_j 所添加的平均噪声 \bar{n}_j
10. 计算完成任务 T_j 所需要花费的平均完成时间 \bar{t}_j
11. while $i \leq |R_w|$ do
12. 根据式(4)对完成此任务的用户 W_i 的诚信度进行更新
13. 根据式(5)对完成此任务的用户 W_i 的活跃度进行更新
14. end while
15. end while

6 理论分析

本章主要对第4章提出的设计目标进行理论分析。

6.1 ϵ -差分隐私

定理1 BCS方案对感知数据满足 ϵ -差分隐私。

证明:用户 W_i 根据自身的隐私预算 $\epsilon_{i,j}$ 和平台预先设定的形状参数 K 生成扰动噪声 $n_{i,j}$,根据式(13)生成 $n_{i,j}^{[23]}$:

$$n_{i,j} = G_1(K, 1/\epsilon_{i,j}) - G_2(K, 1/\epsilon_{i,j}) \quad (13)$$

当用户完成任务后,在任务结果 $O_{i,j}$ 上添加扰动噪声 $n_{i,j}$,

然后将扰动后的结果 $\hat{O}_{i,j}$ 和噪声的绝对值 $|n_{i,j}|$ 上传给平台。虽然平台拥有扰动噪声的绝对值和用户扰动后的结果,但是平台仍无法准确推测出用户的真实数据,在一定程度上减少了用户隐私泄露的风险。最终平台根据各用户上传的扰动后的结果聚合出任务 T_j 的聚合结果 O_j ,整个数据收集的过程中任务聚合结果满足差分隐私,能有效地防止第三方攻击者的恶意攻击。下文将证明向聚合结果 O_j 添加的噪声总量 n_j 服从拉普拉斯噪声机制 $Lap(\sigma_j)$ 。根据伽马分布的比例定律,用户 W_i 对任务 T_j 添加的噪声量为 $\lambda_{i,j} n_{i,j} = \lambda_{i,j} (G_1(K, \sigma_j/\lambda_{i,j}) - G_2(K, \sigma_j/\lambda_{i,j})) = G_1(K, \sigma_j) - G_2(K, \sigma_j)$ 。根据拉普拉斯分布的可除性,可将拉普拉斯分布构造成服从独立同分布的两个伽马分布之差的和,即上文中的式(12),由此证明任务 T_j 在接受数据扰动时添加的噪声总量 n_j 服从拉普拉斯噪声机制 $Lap(\sigma_j)$ 。

6.2 计算有效性

定理2 BCS的时间复杂度为 $O(MN + |T_w| |R_j| + 2|T_w| |R_w|)$ 。

证明:在BCS激励机制中总共包含3种主要算法,分别是筛选算法、匹配算法和激励算法,假设平台有 N 个任务和 M 个用户,筛选算法的主循环会在遍历 N 个任务的同时遍历 M 个用户中的部分用户,我们假设当发生最坏的情况时可以得到其时间复杂度最坏为 $O(MN)$ 。匹配算法中,若有 $|T_w|$ 个任务需要执行,每个待执行的任务有 $|R_j|$ 个用户去完成,我们假设当发生最坏的情况时可以得到其时间复杂度最坏为 $O(|T_s| |R_j|)$ 。激励算法会针对 $|T_w|$ 个任务中每个任务的 $|R_w|$ 个用户进行两次遍历,因此其时间复杂度最坏为 $O(2|T_w| |R_w|)$ 。综上,BCS总的时间复杂度可以表示为 $O(MN + |T_s| |R_j| + 2|T_w| |R_w|)$ 。因此,BCS是计算有效的。

6.3 个体合理性

定理3 BCS激励机制满足个体合理性。

证明:根据匹配算法,若用户 W_i 输掉了任务竞拍,则他的效用 $u_{i,j} = 0$ 。若用户 W_i 为获胜者,则平台会计算此用户获得的报酬,分为两种情况:

1)若 $k = |R_j|$,因为用户的挑选标准是 $d_{i,j} = \frac{b_{i,j}}{s_{i,j}}$,且用户的

成本包含在竞价 $b_{i,j}$ 当中,则用户的 $u_{i,j} = p_{i,j} - c_{i,j} = \frac{s_{i,j}}{\sum_{S_j} s_{i,j}}$ 。

$D - b_{i,j} = \left(\frac{s_{i,j}}{\sum_{S_j} s_{i,j}} \cdot D - d_{i,j} \right) \cdot s_{i,j}$ 。因为用户只有在 $b_{k,j} \leq$

$\frac{s_{k,j}}{\sum_{\sigma=1}^k s_{\sigma,j}} \cdot D$ 时才能获胜,所以 $u_{i,j} \geq 0$ 。

2)若 $0 < k < |R_j|$,则 $u_{i,j} = p_{i,j} - c_{i,j} = \frac{b_{k+1,j}}{s_{k+1,j}} \cdot s_{i,j} - c_{i,j} =$

$\left(\frac{b_{k+1,j}}{s_{k+1,j}} - \frac{b_{i,j}}{s_{i,j}} \right) \cdot s_{i,j} \geq 0$,所以 $u_{i,j} \geq 0$ 。

6.4 真实性

定理4 BCS激励机制满足真实性。

证明:假设用户 W_i 提交虚假报价 $b_{i,j} > p_{i,j}$,根据匹配算法中的式(8),不等式可以写成 $b_{i,j} > \frac{s_{k,j}}{\sum_{\sigma=1}^k s_{\sigma,j}} \cdot D$,分两种情况进行讨论:

1)若 $k = |R_j|$,因为 k 值的挑选标准为 $b_{k,j} \leq \frac{s_{k,j}}{\sum_{\sigma=1}^k s_{\sigma,j}} \cdot D$,

两者矛盾,所以 $b_{i,j} \leq p_{i,j}$ 。

2)若 $0 < k < |R_j|$,则 $b_{i,j} > p_{i,j}$ 可以写成 $b_{i,j} > \frac{b_{k+1,j}}{s_{k+1,j}} \cdot s_{i,j}$,

这时根据 k 的查找条件得知用户不能在竞拍中获胜,所以 $b_{i,j} \leq p_{i,j}$ 。

7 仿真实验

为了评估BCS的性能,我们在操作系统Win10的PC上进行了广泛模拟,该PC的处理器是Intel i7-7700HQCPU@2.80 GHz,内存为32 GB,编程平台选用Matlab2019b。我们使用rSMR拍卖算法^[23]、pSRC拍卖算法^[7]作为基准对比算法,比较了3种方法在平台效用值、任务聚合质量以及任务匹配率方面的效用。

按照表1列出的实验参数进行模拟实验,模拟实验的数据按照表中所示的范围均匀随机生成模拟。实验分成3部分进行,在实验的第一部分,本文展示了3种方法在不同条件下对平台效用值的影响。首先控制执行的任务数量保持不变,让完成任务的用户数量从30逐渐增加到90;然后,作为对照,让完成任务的用户数量不变,让任务数量从20逐渐增加到50。在实验的第二部分,本文使用平均绝对误差(Mean Absolute Error, MAE),验证聚合方法在隐私保护的同时对数据质量保证的有效性。在实验的第三部分,本文讨论了BCS的任务匹配率,在用户数量充足的情况下,让任务数量从20逐渐增加到50,观察任务参与者数量的匹配情况。

表1 参数设置

Table 1 Parameter settings

参数	值	描述
α_j	0.3	任务准确度要求
β_j	0.1	任务准确度要求
b_j	[1, 20]	竞价成本
v_j	[1, 40]	任务价值
$\hat{O}_{i,j}, O_{i,j}$	[0, 1]	感知数据 $O_{i,j}$ 和扰动后的感知数据 $\hat{O}_{i,j}$
N	[20, 50]	任务总数
M	[30, 90]	移动用户总数任务
φ, ρ	0.05	奖惩机制中的奖惩系数
$\theta_{i,j}$	(0, 0.5)	用户可靠度
γ	0.5	综合评分机制权重系数
$t_{i,j}$	[2, 6]	用户执行任务的时间范围

为了保证用户执行任务的合理性,本文设置 $h_{i,j}, a_{i,j}$ 初始值为0.5,禁止得分 $s_{i,j} < 0.1$,或者活跃度 $a_{i,j} < 0.1$,或者诚信度 $h_{i,j} < 0.1$ 的用户参与任务竞拍,将其标记为恶意用户。

7.1 实验分析

表2、表3列出了3种方法运行时间的比较结果。从

表中可以看出,3种方法的运行时间都较短,从总体上来看,3种方法都是计算有效的。BCS的运行时间少于rSMR和pSRC,这是因为rSMR和pSRC的任务分配部分受用户的可靠度影响较大,耗时较长。

表2 不同任务数量下的运行时间

Table 2 Runtime with different task numbers

N	25	30	35	40	45	50
BCS	0.06	0.04	0.06	0.03	0.04	0.03
rSMR	0.22	0.17	0.33	0.24	0.29	0.35
pSRC	0.17	0.17	0.18	0.19	0.30	0.30

表3 不同用户数量下的运行时间

Table 3 Runtime with different user numbers

M	40	50	60	70	80	90
BCS	0.08	0.05	0.02	0.04	0.04	0.03
rSMR	0.18	0.21	0.17	0.13	0.11	0.10
pSRC	0.20	0.16	0.23	0.18	0.41	0.41

如图4所示,随着参与的用户数量增大,BCS得出的平台效用值逐渐增加,而rSMR和pSRC的平台效用值在一个较低的区间范围内上下波动。此外,可以观察到BCS优于其他两种方案,这是因为随着参与的用户增多,彼此之间的竞争增大,BCS以用户的综合得分为基础,以用户报价做参考,使用户和任务之间的匹配更平衡,任务匹配率会更高,可以选出更多低成本的高质量任务参与者以降低平台成本;rSMR和pSRC的方案受用户可靠度的影响较大,两者容易陷入局部最优。




图4 不同用户数量下的平台效用值

Fig. 4 Platform utility values with different user numbers

如图5所示,随着任务数量的增加,BCS得到的平台效用值逐渐增大,rSMR和pSRC所得平台效用值则维持在一个较低的区间范围。同时可以看出BCS优于其他两种方案,这是因为BCS兼顾用户的综合得分和报价,用户和任务的匹配也会更加均匀,任务匹配率会更高,不容易像其他两种方案那样陷入局部最优,出现算法运行时任务和用户的匹配程度反而降低,无法选出更多低成本的高质量任务参与者的情况。




图5 不同任务数量下的平台效用值

Fig. 5 Platform utility values with different task numbers

如图6、图7所示,BCS得到的MAE比rSMR和pSRC

更平稳,pSRC出现了小范围的波动,rSMR则出现了大范围的波动。这说明pSRC和rSMR不稳定,这是因为BCS可以选出更多高质量的任务参与者,它们采用基于权重的聚合方式得到的权重更多,因此数据的质量会更好,而一方面rSMR和pSRC的任务匹配率不如BCS,另一方面算法易陷入局部最优,也不能使任务和用户的匹配更加均匀。




图6 不同用户数量下的MAE

Fig. 6 MAE with different user numbers




图7 不同任务数量下的MAE

Fig. 7 MAE with different task numbers

另外,总体来看,3种方式得到的MAE均较小,这表示基于权重的数据聚合方式的任务聚合结果具有合理性。

如图8所示,随着任务数量的增加,BCS,rSMR和pSRC这3种方法的任务参与者匹配数量均有不同程度的增加,BCS的任务参与者匹配数量高于rSMR和pSRC,这说明BCS在提高任务匹配率方面的性能更好。这是因为在任务分配的过程中,BCS同时关注用户的综合得分和报价,这两者都是任务匹配所参考的重要因素。




图8 不同任务数量下的参与者匹配

Fig. 8 Participant matching with different task numbers

结束语 为了保证用户隐私安全的同时有效促进用户积极地参与到任务中,本文提出了一种基于综合评分的双边拍卖隐私激励机制BCS。这种新的激励机制以双边拍卖模型为基础进行建模,综合考虑了多种因素对用户完成感知任务的影响,将系统给出的综合评分作为筛选高质量用户的依据,在一定程度上提高了用户和任务的匹配程度,同时结合本地化差分隐私保护技术,做到了对用户隐私的良好保护。为了评估BCS,我们在模拟数据集上进行了实验,并与rSMR方法

和 pSRC 方法进行了比较。实验结果表明,BCS 可以在提高平台收益和任务匹配率的同时保证感知数据质量。本文实验所用数据集是在比较理想的条件下生成的,由于真实的实验数据难以获取,本文实验尚未结合真实的实验数据集来做进一步的验证,在未来的研究中,将进一步寻找合适的数据集来验证 BCS 的有效性。

参 考 文 献

- [1] MA H,ZHAO D,YUAN P.Opportunities in mobile crowd sensing[J]. IEEE Communications Magazine, 2014, 52(8): 29-35.
- [2] HASENFRATZ D,SAUKH O,WALSER C,et al. Deriving high-resolution urban air pollution maps using mobile sensor nodes[J]. Pervasive and Mobile Computing, 2015, 16:268-285.
- [3] LIU Z,JIANG S,ZHOU P,et al. A participatory urban traffic monitoring system: The power of bus riders[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(10): 2851-2864.
- [4] YE Q Q,MENG X F,ZHU M J,et al. Survey on local differential privacy[J]. Journal of Software, 2018, 29(7):1981-2005.
- [5] TAO X,SONG W. Efficient path planning and truthful incentive mechanism design for mobile crowdsensing[J]. Sensors, 2018, 18(12):4408.
- [6] CHEN Y,ZHANG J,WU K,et al. TAMES: A truthful double auction for multi-demand heterogeneous spectrums[J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 25(11):3012-3024.
- [7] JIN H,SU L,XIAO H,et al. Incentive mechanism for privacy-aware data aggregation in mobile crowd sensing systems[J]. IEEE/ACM Transactions on Networking, 2018, 26(5):2019-2032.
- [8] WU Y,ZENG J R,PENG H,et al. Survey on Incentive Mechanisms for Crowd Sensing[J]. Journal of Software, 2016, 27(8): 2025-2047.
- [9] YANG G,HE S,SHI Z,et al. Promoting cooperation by the social incentive mechanism in mobile crowdsensing[J]. IEEE Communications Magazine, 2017, 55(3):86-92.
- [10] AMINTOOSI H,KANHERE S S,TORSHIZ M N. A socially-aware incentive scheme for social participatory sensing[C]// 2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP). IEEE, 2015:1-6.
- [11] JAIMES L G,VERGARA-LAURENS I J,RAIJ A. A survey of incentive techniques for mobile crowd sensing[J]. IEEE Internet of Things Journal, 2015, 2(5):370-380.
- [12] MUSTHAG M,RAIJ A,GANESAN D,et al. Exploring micro-incentive strategies for participant compensation in high-burden studies[C]// Proceedings of the 13th International Conference on Ubiquitous Computing. 2011:435-444.
- [13] SINGH V K,JUSTIA S,SINGH S K,et al. A Quality Aware Multiunit Double Auction Framework for IoT-Based Mobile Crowdsensing in Strategic Setting[J]. IEEE Access, 2022, 10: 67976-67999.
- [14] JIA B,CEN H,LUO X,et al. An Online Intelligent Task Pricing Mechanism Based on Reverse Auction in Mobile Crowdsensing Networks for the Internet of Things[C]// 2021 IEEE Symposium Series on Computational Intelligence(SSCI). IEEE, 2021: 1-6.
- [15] LIN X,ZHANG K. Encyclopedia of Wireless Networks[M]. Springer International Publishing, 2020.
- [16] JI G,YAO Z,ZHANG B,et al. A reverse auction-based incentive mechanism for mobile crowdsensing[J]. IEEE Internet of Things Journal, 2020, 7(9):8238-8248.
- [17] ZHANG X,GAO L,CAO B,et al. A double auction mechanism for mobile crowd sensing with data reuse[C]// 2017 IEEE Global Communications Conference(GLOBECOM 2017). IEEE, 2017:1-6.
- [18] DWORC C. Differential privacy[C]// Automata, Languages and Programming: 33rd International Colloquium (ICALP 2006). Venice, Italy, Part II 33. Berlin Heidelberg: Springer, 2006: 1-12.
- [19] WANG J,WANG Y,ZHAO G,et al. Location protection method for mobile crowd sensing based on local differential privacy preference[J]. Peer-to-Peer Networking and Applications, 2019, 12:1097-1109.
- [20] LI F,SONG H,LI J. Personalized Data Collection Based on Local Differential Privacy in the Mobile Crowdsensing[C]// 2020 IEEE 6th International Conference on Computer and Communications(ICCC). IEEE, 2020:2048-2052.
- [21] YANG M,ZHU T,XIANG Y,et al. Density-based location preservation for mobile crowdsensing with differential privacy[J]. IEEE Access, 2018, 6:14779-14789.
- [22] GHOSH A,ROTH A. Selling privacy at auction [C]// Proceedings of the 12th ACM Conference on Electronic Commerce. 2011:199-208.
- [23] CHEN D. Research on crowd sensing incentive mechanism for localized privacy protection [D]. Chongqing:Chongqing University, 2021.



FU Yanming, born in 1976, Ph.D, associate professor. His main research interests include data mining, network security, crowd-sensing, etc.



ZHANG Siyuan, born in 1999, postgraduate. His main research interests include mobile crowd-sensing and incentive mechanism, privacy protection.