本地差分隐私下技能感知的任务分配算法研究

方贤进[①②] 甄雅茹[①] 张朋飞[*①②] 黄珊珊[①]

[①](安徽理工大学计算机科学与工程学院 淮南 232001)

[②](安徽理工大学煤炭无人化开采数智技术全国重点实验室 淮南 232001)

摘 要：空间众包任务分配依托平台将具有地理位置属性的任务指派给周边工人，然而工人在上传实时位置信息过程中，行踪易被泄露或滥用，存在隐私风险。现有方法虽采用可信第3方或差分隐私进行位置扰动，但在多技能任务及技能分布不均场景下难以兼顾隐私保护与分配效率。为此，该文提出一种融合隐私保护与技能感知的协同分配算法。首先采用截断拉普拉斯机制对工人位置加噪，在满足本地差分隐私的同时降低定位偏差；其次引入基于信息熵的技能多样性评估指标，并设计动态策略优化工人集合技能分布；最后再构建基于技能贡献值的贪婪算法，并结合时空与预算约束提出3种剪枝策略提升计算效率。实验结果表明，该方法在服务质量损失、任务完成率与平均预算剩余率等方面表现优良，实现了隐私保护与任务分配效率之间的有效平衡。

关键词：空间众包；任务分配；本地差分隐私；技能多样性；贪婪算法

中图分类号：TN918; TP391 **文献标识码**：A **文章编号**：1009-5896(2025)11-4429-11

DOI: 10.11999/JEIT250425 **CSTR**: 32379.14.JEIT250425

1 引言

空间众包(Spatial Crowdsourcing, SC)以复杂任务大众化的方式，在全球范围内为有偿或义务工作的工人和任务进行高质量的匹配，已成为21世纪经济中不可避免的角色[1]。空间众包已在多个领域得到广泛应用，如外卖配送[2]、物流[3]和网约车[4]等。任务分配作为空间众包的一项基础研究，其挑战在于如何高效匹配异构任务与工人资源。现有空间众包任务不再依赖非专业工人完成简单任务，如定位拍照、包裹配送[5]等，某些复杂任务还需工人特定技能支持，甚至多技能协作，如技术维修、活动筹备[6]等。受此启发，本文考虑了在线即时多技能任务分配场景(online instant Multi-Skill Task Assignment scenarios, MS-TA)中工人技能组合与复杂任务需求精准匹配的问题。

在任务分配中，工人需向平台提供真实位置进行任务查询，但不可信的服务方可能泄露这些敏感数据，进而威胁工人安全并降低其参与意愿[7]。本地差分隐私(Local Differential Privacy, LDP)通过在数据采集前进行本地扰动，工人利用模糊位置与平台交互，有效解决了该隐私困境[8]。实现LDP的方法有高斯机制[9]、指数机制[10]，拉普拉斯机制[11,12]等，而本文将采用截断拉普拉斯机制[13]实现对工人位置加噪，通过控制噪声生成范围，使扰动后的模糊位置不会过分偏离真实位置，其不仅避免了中心化存储的隐私泄露风险，还保证了数据的可用性。基于此，本文将传统多技能任务分配(MS-TA)问题扩展为隐私保护下的多技能任务分配(MS-PriTA)问题，重点研究在LDP框架下如何实现高效的任务匹配。

任务分配作为空间众包领域的核心问题，长期受到众多学者的关注与深入研究[14]。Huang等人[15]聚焦于时间相关的众包系统任务分配问题，提出了针对性的时间相关任务分配模型和解决方案。Liu等人[16]受到群体策略的启发，针对轻量级算法GMA忽略多技能工人可减少总行程距离的问题，提出改进算法以有效降低距离成本。Tao等人[17]在预算约束下通过深度学习设计多任务异构框架，实现平台收益最大化并提升任务分配效率。Song等人[18]面向多技能任务分配，提出在线精确分配算法，为动态出现的任务或工人计算最优分配。Han等人[19]为应对任务和工人在线聚集所带来的复杂要求，引入层次树和时间序列队列，并从计算模式、树的创建方法以及匹配策略的扩展3个方面研究了在线大规模异构任务分配问题。Hong等人[20]提出轨迹感知的本地差分隐私方法，通过卡尔曼滤波识别轨迹中的重要位置点，并采用自适应隐私预算分配机制提升数据实用性。Wei等人[21]设计了基于可信第3方的隐私保护方案，但实际场景中可信服务提供商的可靠性难以保证。为此，Wang等人[22]提出无须可信方的地理不可区分性方案，并结合混合整数非线性规划以优化工人移动距离。Béziaud等人[23]介绍了

收稿日期：2025-05-15；改回日期：2025-09-16；网络出版：2025-09-23

*通信作者： 张朋飞 zpf.bupt@bupt.cn

基金项目：国家自然科学基金(61572034)

Foundation Item: The National Natural Science Foundation of China (61572034)

一种轻量级隐私保护方法，允许工人在本地对其技能参数进行扰动，并构建可集成于传统任务分配算法的权重函数，通过技能分类法有效应对差分隐私扰动的影响。

现有研究已从任务完成率和调度优化等角度对空间众包任务展开深入探讨，部分工作也关注了多技能任务分配问题，但对工人集合中技能多样性及其均衡性的重视仍显不足。对于在线即时任务，响应速度和匹配精度至关重要，技能分布均衡可最大化任务率并提高系统响应速度。此外，许多研究尚未考虑工人的位置隐私问题，削弱了系统的实用性并降低工人的参与意愿。总体而言，当前研究多将技能多样性与隐私保护割裂，缺乏对复杂任务中多技能覆盖需求、位置隐私保护与任务约束条件之间的协同优化。尽管差分隐私是有效的加噪手段，但如何在保护隐私的同时合理控制噪声强度，以确保数据失真可控与任务分配精度，仍是亟待解决的挑战。

综上，本文的贡献有：(1)技能多样性的评估与优化：针对工人集合技能分布不均衡问题，引入熵作为技能多样性的评价指标，并设计基于熵阈值的“二次筛选”策略，剔除部分高比例技能工人，优先选取低比例技能工人，从而确保技能分布均衡化。(2)基于本地差分隐私的隐私保护：采用截断拉普拉斯机制实现工人位置隐私保护，在满足本地差分隐私要求的同时，确保加噪位置与真实位置的偏差控制在合理范围内，兼顾了隐私安全性与数据实用性。(3)任务分配算法的设计与优化：提出技能感知的剪枝贪婪任务分配算法(skill-aware PrUning GReedy task assignment algorithm, PUGR)，其基于技能贡献值迭代选择工人，并结合时间距离剪枝、高报酬剪枝和预算剪枝3种优化策略，提升计算效率。(4)实验验证：在3个真实数据集上的实验结果表明，所提方法在隐私保护强度、任务分配效率和服务质量损失等方面均表现出优越性能。

2 预备知识

2.1 本地差分隐私

本地差分隐私是一种确保数据在收集前已经被扰动的方法，这种扰动操作由工人本地完成，不依赖于中心化的可信方，使得服务提供者无法直接获取真实数据，从而保护工人隐私。

定义1 (本地差分隐私ε-LDP)

随机算法$\mathcal{M}$满足ε-LDP，如果对于任意工人的2个可能输入x和x'以及任何可能的输出y，都有

$$\Pr\left(\mathcal{M}\left(x\right)=y\right)\le \mathrm{e}^{\varepsilon}\Pr\left(\mathcal{M}\left(x'\right)=y\right) \tag{1}$$

定义2 (拉普拉斯机制(LaPlace mechanism, LP))

给定任意函数$f:\mathcal{D}\to\mathcal{Z}$和相邻数据集$D$和$D'$，设$\Delta f=\max\left\|f\left(D\right)-f\left(D'\right)\right\|_1$为灵敏度函数，拉普拉斯机制$M\left(D\right)=f\left(D\right)+\eta$满足$\varepsilon$-LDP，其中$\eta$为随机变量，服从分布$\mathrm{Lap}\left(0,\dfrac{\Delta f}{\varepsilon}\right)$。

2.2 问题定义

本文涉及的主要符号及其含义见表1。在时间点p，给定工人集$\mathcal{W}$，工人w_i的位置为$l_i\left(p\right)$，移动速度为v_i，最大移动距离为d_i；任务集$\mathcal{T}$，任务t_j的位置为l_j，截止时间为e_j，预算为$\mathcal{B}_j$。若工人的技能$\mathcal{X}_i\in\mathcal{A}$满足任务的技能需求$\mathcal{Y}_j\in\mathcal{A}$，且工人可在截止时间之前到达任务$t_j$的位置并满足最大移动距离限制，则在工人完成任务后支付其报酬b_{ij}。任务分配结果集$\mathcal{R}$是满足技能、时间、距离和预算约束的工人-任务配对集合。现将空间众包中隐私保护下的多技能任务分配问题形式化为

$$\begin{aligned}
&\max\sum_{t_j\in\mathcal{T}}\left(\mathcal{B}_j-\sum_{i=1}^{n}b_{ij}x_{ij}\right)\\
&\text{s.t. }\mathrm{dist}\left(l_j,l_i'\left(p\right)\right)\le\min\left(\left(e_j-p\right)\cdot v_i,d_i\right),\\
&\qquad\qquad i=1,2,\cdots,n;j=1,2,\cdots,m\\
&\mathcal{Y}_j\subseteq\cup_{i=1}^{n}\mathcal{X}_i\wedge x_{ij}\quad t_j\in\mathcal{T}\\
&\sum_{i=1}^{n}b_{ij}x_{ij}\le\mathcal{B}_j\qquad j=1,2,\cdots,m\\
&\sum_{j=1}^{m}x_{ij}\le 1\qquad i=1,2,\cdots,n
\end{aligned}\tag{2}$$

由于上述MS-PriTA问题涉及多个空间任务，并要求在满足多重约束下为工人和任务构建匹配策略，而现有的集合覆盖问题(Set Cover Problem,

表 1 符号及含义

符号	描述
$\mathcal{T}$	在时间点p处的$\mathcal{M}$个空间任务t_j的集合
$\mathcal{W}$	在时间点p处的$\mathcal{N}$个工人w_i的集合
$\mathcal{W}'$	实现技能多样性均衡的工人集合
$\mathcal{A}$	系统中存在的技能集合
e_j	到达任务t_j所在位置的截止时间
$l_i\left(p\right)$	工人w_i在时间点p时的真实位置
$l_i'\left(p\right)$	工人w_i在时间点p时的模糊位置
l_j	任务t_j的位置
$\mathcal{X}_i$	工人w_i拥有的一组技能
$\mathcal{Y}_j$	任务t_j所需技能的集合
d_i	工人w_i的最大移动距离
$\mathcal{B}_j$	任务t_j的最大预算
$\mathcal{R}$	时间点p时的任务分配结果集

SCP)近似算法无法直接应用，所以空间众包中隐私保护下的多技能任务分配MS-PriTA问题是NP-hard。

证明　将MS-PriTA约简为SCP, SCP的定义为：给定全集$\mathcal{U}$和m个子集$\mathcal{Z}_1,\mathcal{Z}_2,\cdots,\mathcal{Z}_m\subseteq\mathcal{U}$。每个子集$\mathcal{Z}_i$都与成本$c_i$相关联，目标是找到一个集合$\mathcal{K}\subseteq\{1,2,\cdots,m\}$，最小化$\sum_{i\in\mathcal{K}}c_i$，使得$\cup_{i\in\mathcal{K}}\mathcal{Z}_i=\mathcal{U}$。

构建约简：在时间点p处，给定任务t_j，其所需技能集为$\mathcal{Y}_j=\mathcal{U}$，预算值$\mathcal{B}_j$足够雇佣满足所需技能的工人，截止时间$e_j$足够让任何工人及时到达。对于$m$个工人，每个工人$w_i$都有一个技能集，即$\mathcal{X}_i=\mathcal{Z}_i$，报酬$b_{ij}=c_i$，且最大移动距离$d_i$足够覆盖任务位置。工人集$\mathcal{K}'$满足

$$\mathcal{Y}_j\subseteq\cup_{i\in\mathcal{K}'}\mathcal{X}_i,\ \text{maximize}\left(\mathcal{B}_j-\sum_{i\in\mathcal{K}'}b_{ij}\right)\Rightarrow\text{minimize}\sum_{i\in\mathcal{K}'}b_{ij}\iff\text{minimize}\sum_{i\in\mathcal{K}}c_i\tag{3}$$

由该映射，易证明只有当且仅当变换后的多技能任务分配问题可以求解时，集合覆盖问题才能求解。由于SCP是已知的NP-hard问题[24]，故MS-PriTA问题亦为NP-hard。

证毕

3　技能感知隐私保护任务分配算法

3.1　基于熵的技能感知均衡优化策略

实际任务分配中，技能分布不均常导致分配失败。如图1所示，任务t_1,t_2,t_3周边分布着8名技能各异的工人，每名工人均设定了移动速度和最大移动距离。为实现最优任务分配，平台需选择既能满足技能需求又符合时空约束的工人组合。具体而言，任务t_1可由工人$\{w_2,w_7,w_8\}$完成，但在w_2,w_7,w_8已被分配的情况下，任务t_2和t_3的最优工人集合分别为$\{w_1,w_3,w_5\}$和$\{w_3,w_4,w_5\}$，导致任务t_2和t_3无法同时分配成功。经分析，该冲突源于

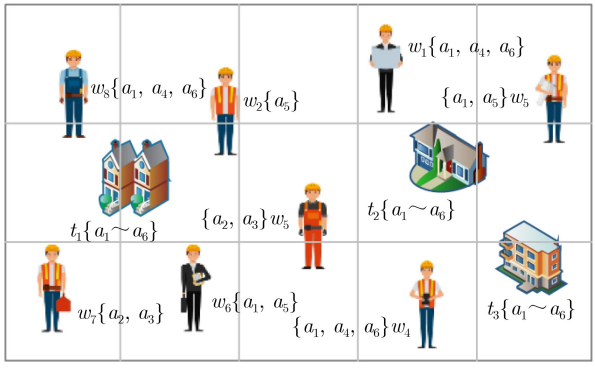

图 1 多技能任务分配中旧屋修缮实例

工人集合技能分布不均衡，即某种技能(a_1)的工人过剩，而其他技能(a_2)的工人相对稀缺。若优化工人集合的技能均衡性(见算法1)，则可有效避免上述任务分配失败情况。

为了衡量工人集合技能分布的多样性，利用信息论中的熵，通过计算分配给每个任务的工人集合技能分布的熵值来衡量其多样性。对于任务t_j，分配一组工人$\mathcal{W}=\{w_1,w_2,\cdots,w_n\}$，其中$n$表示参与任务$t_j$的工人数($n\ll\mathcal{N}$，$\mathcal{N}$为工人总数)。每个工人$w_i$拥有其技能集合$\mathcal{X}_i\in\mathcal{A}$。当工人响应任务$t_j$请求时，首先计算各技能在工人技能集合中所占比例。记p_{a_i}为在意愿参与任务t_j的工人集合中拥有技能a_i的概率

$$p_{a_i}=\frac{\text{sum}\,(a_i)}{n}\tag{4}$$

其中$\text{sum}\,(a_i)$表示拥有技能a_i的工人总数。根据技能分布的概率p_{a_i}计算初步技能分布的熵值

$$H\,(t_j)=-\sum_{i=1}^{k}p_{a_i}\log\,(p_{a_i})\tag{5}$$

熵值$H\,(t_j)$越高，表示任务t_j分配的工人技能越均匀，覆盖任务所需技能的可能性越大，即技能多样性越高；熵值越低，表示某些技能主导任务，技能多样性越低。为确保技能分布不均时仍能公平选择不同技能，当工人集合技能熵值低于阈值时，引入“二次筛选”，按技能比例设置无效值概率p_{in}，高比例技能被设置为无效的概率大，低比例技能的概率小，从而增加了集合中稀有技能工人的参与机会。

定义3(无效值概率)不同技能成为无效值的概率与它们所占的比例成正比

$$p_{\text{in}}\,(a_i)=p_{\min}+(p_{\max}-p_{\min})\cdot\frac{p\,(a_i)}{\mathcal{P}_{\max}}\tag{6}$$

其中，$p_{\max}$和$p_{\min}$分别为最大与最小无效值概率，$\mathcal{P}_{\max}$为技能中比例最大的技能，即$\mathcal{P}_{\max}=\max_{a_i\in X_i}p\,(a_i)$。为了实现上述基于熵的技能均衡优化策略，其具体步骤如算法1所示。

3.2　截断拉普拉斯机制下的位置隐私保护

拉普拉斯机制通过向数据添加从拉普拉斯分布中采样的噪声来保护隐私(见算法2)，其公式为

$$\eta\sim\text{Lap}\left(0,\frac{\Delta f}{\varepsilon}\right)\tag{7}$$

由于拉普拉斯机制噪声的随机性和无界性，直接对工人位置数据加噪可能导致位置偏离过大，从而增加旅行成本并降低任务分配效用，鉴于此，引入截断拉普拉斯机制加以解决。

算法 1 技能多样性均衡化

输入：$\mathcal{W},\mathcal{X}_i,\mathcal{T},\mathcal{Y}_j,\hat{H},p_{\min},p_{\max}$
输出：$\mathcal{W}'$
(1) 初始化$\mathcal{W}'=\varnothing$，$\mathcal{I}=\varnothing$
(2) for $a_i\in\mathcal{A}$：$p_{a_i}\leftarrow$式(4)
(3) $H(t_j)\leftarrow$式(5)
(4) if $H(t_j)<\hat{H}$：$p_{\text{in}}(a_i)\leftarrow$式(6)
(5) for $w_i\in\mathcal{W}$：
(6) for $a_i\in\mathcal{X}_i$：
(7) if random$(0,1)\le p_{\text{in}}(a_i)$：$a_i\leftarrow$无效值，$\mathcal{I}\leftarrow\mathcal{I}\cup\{a_i\}$
(8) if $\mathcal{I}\ne\mathcal{X}_i$：$\mathcal{W}'\leftarrow\mathcal{W}'\cup\{w_i\}$
(9)return $\mathcal{W}'$

定义4（截断拉普拉斯机制(Clip-LaPlace mechanism, CLP)）

设任意函数$f:\mathcal{U}\to\mathcal{V}$，其灵敏度为$\Delta f=\|f(X)-f(X')\|_1$，其中$X$和$X'$为任意相邻的数据集。Clip-Laplace 机制定义为$M:\mathcal{V}\to\mathcal{Q}$。其中每个随机变量$\mathcal{Q}\in Q$服从分布$\text{CLap}(f(x),\lambda,A)$，其概率密度函数为

$$p(z)=\begin{cases}\dfrac{1}{\vartheta}\cdot\dfrac{1}{2\lambda}\exp\left(-\dfrac{|z-f(x)|}{\lambda}\right), & -A\le z\le A\\ 0, & \text{其他}\end{cases}\tag{8}$$

上式中的归一化因子$\vartheta=1-\dfrac{1}{2}\left[\exp\left(-\dfrac{f(x)+A}{\lambda}\right)+\exp\left(-\dfrac{A-f(x)}{\lambda}\right)\right]$，$A\ge\dfrac{\Delta f}{2}$。

定理1 当$f(x)\in\left[-\dfrac{\Delta f}{2},\dfrac{\Delta f}{2}\right]$和$\lambda=\dfrac{\Delta f}{\varepsilon}$时，截断拉普拉斯机制满足$\varepsilon$-LDP。

证明 设X和X'是两个相邻的数据集，其输出分别为$f(X)$和$f(X')$，且$|f(X)-f(X')|\le\Delta f$。截断拉普拉斯机制的概率密度比为

$$\frac{\Pr[M(X')=z]}{\Pr[M(X)=z]}=\exp\left(\frac{|z-f(X')|-|z-f(X')|}{\lambda}\right)\tag{9}$$

由三角不等式可得，对于任意$z\in\mathbb{R}$和任意相邻数据集X, X'，均有

$$||z-f(X')|-|z-f(X)||\le|f(X')-f(X)|\le\Delta f\tag{10}$$

代入上式，得

$$\exp\left(\frac{|z-f(X')-|z-f(X')||}{\lambda}\right)\le\exp\left(\frac{\Delta f}{\lambda}\right)\tag{11}$$

当$\lambda=\dfrac{\Delta f}{\varepsilon}$时，有

$$\frac{\Pr[M(X')=z]}{\Pr[M(X)=z]}\le\exp\left(\frac{\Delta f}{\lambda}\right)=\exp\left(\frac{\Delta f}{\frac{\Delta f}{\varepsilon}}\right)=\exp(\varepsilon)\tag{12}$$

证毕

基于上述截断拉普拉斯机制，其加噪实现流程如算法2所示。

3.3 基于技能贡献值的贪婪任务分配算法

本算法每次依据技能贡献值$\Delta\mathcal{S}_i$贪婪地选择一个工人和任务分配，即(w_i,t_j)，从而在满足技能要求的情况下最大限度地提高任务剩余预算$\mathcal{B}'_j$。

$$\Delta\mathcal{S}_i=\frac{\left|\mathcal{X}_i\cap\left(\mathcal{Y}_j-\tilde{\mathcal{Y}}_j\right)\right|}{|\mathcal{Y}_j|}\tag{13}$$

$$\mathcal{B}'_j=\mathcal{B}_j-\sum_{(w_i,t_j)\in\mathcal{R}}b_{ij}\tag{14}$$

其中，$\tilde{\mathcal{Y}}_j$表示任务t_j已被指派工人覆盖的技能集合。式(13)反映了任务t_j中新工人w_i可以掌握的技能比例，即工人集合中每个候选工人对技能覆盖的贡献值。

具体来说，贪婪算法的核心策略是每次选择对当前任务增益最大的工人w_i，即在每一步选择时保证

$$\forall w_i,w_r\in\mathcal{W}',\ \Delta\mathcal{S}_i(w_i,t_j)\ge\Delta\mathcal{S}_r(w_r,t_j)\tag{15}$$

且当$\Delta\mathcal{S}_i(w_i,t_j)=\Delta\mathcal{S}_r(w_r,t_j)$时，有$b_{ij}\le b_{rj}$，因此，贪婪算法的每次选择在当前状态下是最优的。

3.4 任务分配的高效剪枝优化

技能贡献值$\Delta\mathcal{S}_i$用于评估工人和任务的配对，贪婪算法每次在$\mathcal{S}$中选择$\Delta\mathcal{S}_i$最高的工人与任务配对，并将其添加到$\mathcal{R}$中。为避免低效的枚举计算，将引入3种有效的剪枝策略。

策略1(时间与距离剪枝)：对于任务t_j和参与该任务的工人w_i，若工人无法在任务截止时间前到达任务位置或工人到任务位置的距离超过其定义的最大移动距离，则安全剪除该工人-任务配对(w_i,t_j)。

策略2(剪枝高报酬的工人)设$\tilde{b}_{\cdot j}$为已分配给任务t_j的工人的总报酬，若将工人w_i分配到任务t_j的

算法 2 加噪机制

输入：$(x,y),\varepsilon,\Delta f,A\ge\dfrac{\Delta f}{2}$
输出：(x',y')
(1) $\lambda\leftarrow\dfrac{\Delta f}{\varepsilon}$
(2) for $z\in(x,y)$：$\eta_z\sim\text{Laplace}(0,\lambda,A)$；
(3) $x'\leftarrow x+\eta_x$；$y'\leftarrow y+\eta_y$
(4) return (x',y')

报酬b_{ij}大于任务t_j的剩余预算$\left(\mathcal{B}_j-\tilde{b}_{\cdot j}\right)$，则不会将工人$w_i$分配到任务$t_j$。

策略3(剪枝预算不足的任务)对于任务t_j，若在未分配工人集合中任何能覆盖任务技能集的组合其总旅行成本均超过任务的剩余预算$\left(\mathcal{B}_j-\tilde{b}_{\cdot j}\right)$，则该任务被剪枝。

结合上述技能贡献值计算与三类剪枝策略，完整的PUGR任务分配流程如算法3所示。起初，将结果集合$\mathcal{R}$，技能覆盖集合$\mathcal{R}_s$置为空，并将任务的剩余预算$\mathcal{B}'_j$初始化为其初始预算$\mathcal{B}_j$。随后，利用时间与距离剪枝筛除不可达工人。若$\mathcal{W}'=\varnothing$或$\mathcal{T}=\varnothing$，则直接返回$\mathcal{R}$。对于每个任务t_j，在技能需求$\mathcal{Y}_j$尚未完全覆盖且$\mathcal{W}'\neq\varnothing$时，计算所有候选工人的技能贡献值$\Delta\mathcal{S}_i$，选取贡献值最大的工人$w'$。接着，执行高报酬工人剪枝，判断该工人的报酬是否满足$b_{ij}\le\mathcal{B}'_j$。若满足预算约束，则进行预算不足任务剪枝，将w'加入$\mathcal{R}$，并更新$\mathcal{R}_s$, $\mathcal{B}'_j$及候选工人集合$\mathcal{W}''$；直到当前任务的技能需求$\mathcal{Y}_j$完全被覆盖后，继续下一个任务，若无法覆盖，则返回FALSE。最终，当所有任务处理完成，返回结果集合$\mathcal{R}$。

3.5 算法效用分析

在本节中，将通过次模性分析、近似比推导以及复杂度评估3方面对PUGR算法(算法3)进行阐述。首先，算法核心依赖于目标函数的次模性质，对任意工人集合$\mathcal{G}$，新增w的边际增益为

$$\Delta\left(w\,|\mathcal{G}\right)=\frac{|\mathcal{X}\left(w\right)\backslash\mathcal{C}\left(\mathcal{G}\right)|}{|\mathcal{Y}\left(t\right)|}\tag{16}$$

算法 3　PUGR算法

输入：$\mathcal{W}'$,$\mathcal{T}$
输出：$\mathcal{R}$

(1) $\mathcal{R}=\varnothing$，$\mathcal{R}_s=\varnothing$，$\mathcal{B}'_j\leftarrow\mathcal{B}_j$
(2) $\mathcal{W}'\leftarrow$剪枝时间或距离不符的工人
(3) if $\mathcal{W}'=\varnothing$ or $\mathcal{T}=\varnothing$：return $\mathcal{R}$
(4) for $t_j\in\mathcal{T}$：
(5)　while $\mathcal{R}_s\neq\mathcal{Y}_j$ and $\mathcal{W}'\neq\varnothing$：
(6)　　$\Delta\mathcal{S}_i\leftarrow$计算技能贡献值$(w_i,\mathcal{Y}_j,\mathcal{R}_s)$
(7)　　$w'\leftarrow\arg\max_{w_i\in\mathcal{W}''}\mathcal{S}$
(8)　　$\mathcal{W}''\leftarrow$剪枝高报酬的工人
(9)　　if $b_{ij}\le\mathcal{B}'_j$：
(10)　　$\mathcal{T}\leftarrow$剪枝预算不足的任务
(11)　　$\mathcal{R}\leftarrow\mathcal{R}\cup\{w'\}$, $\mathcal{R}_s\leftarrow\mathcal{R}_s\cup\mathcal{X}_i\left[w'\right]$
(12)　　$\mathcal{B}'_j\leftarrow\mathcal{B}_j{}'-b_{w'}$, $\mathcal{W}''\leftarrow\mathcal{W}''-\{w'\}$
(13)　　else: return FALSE
(14)　if $\mathcal{R}_s\neq\mathcal{Y}_j$：return FALSE
(15) return $\mathcal{R}$

即w能提供但$\mathcal{G}$未覆盖的技能比例，其中$\mathcal{X}\left(w\right)$为工人$w$的技能集，$\mathcal{Y}\left(t\right)$为任务$t$的技能需求集，$\mathcal{C}\left(\mathcal{G}\right)$为已选工人的技能覆盖集。

由$\mathcal{G}_1\subseteq\mathcal{G}_2$可得$\mathcal{C}\left(\mathcal{G}_1\right)\subseteq\mathcal{C}\left(\mathcal{G}_2\right)$，因此

$$\mathcal{X}\left(w\right)\backslash\mathcal{C}\left(\mathcal{G}_2\right)\subseteq\mathcal{X}\left(w\right)\backslash\mathcal{C}\left(\mathcal{G}_1\right)\tag{17}$$

$$\begin{aligned}\Delta\left(w\,|\mathcal{G}_1\right)&=\frac{|\mathcal{X}\left(w\right)\backslash\mathcal{C}\left(\mathcal{G}_1\right)|}{|\mathcal{Y}\left(t\right)|}\ge\frac{|\mathcal{X}\left(w\right)\backslash\mathcal{C}\left(\mathcal{G}_2\right)|}{|\mathcal{Y}\left(t\right)|}\\&=\Delta\left(w\,|\mathcal{G}_2\right)\end{aligned}\tag{18}$$

从而确保贪婪算法的局部最优选择能够逼近全局最优解。

进一步地，算法的近似比可结合上述次模性分析严格推导。设$\mathcal{G}_t$为任务t的工人集合，若忽略所有约束，贪婪算法每次迭代选择边际增益最大的工人

$$w^*=\arg\max_{w\in W_t}\Delta\left(w\,|\mathcal{G}_t\right)\tag{19}$$

根据次模函数优化理论，其近似比为

$$\mathcal{C}\left(\mathcal{G}_{\text{final}}\right)\ge\left(1-\frac{1}{\mathrm{e}}\right)\mathcal{C}\left(\mathcal{G}_{\text{opt}}\right)\tag{20}$$

在考虑时空剪枝约束时，引入保留率因子$\alpha\in(0,1]$，考虑隐私保护约束，截断拉普拉斯机制引入的误差为$\varepsilon\le\dfrac{2\Delta f}{\rho}$，则最终的近似比为$\mathcal{C}\left(\mathcal{G}_{\text{final}}\right)\ge\alpha\left(1-\dfrac{1}{\mathrm{e}}\right)\mathcal{C}\left(\mathcal{G}_{\text{opt}}\right)-\varepsilon$。

工人通过在本地扰动自己的位置信息，即可满足严格的差分隐私模型，而无须额外的通信或计算成本。其时间复杂度主要来源于工人与任务配对的遍历与每次迭代中技能贡献值的计算，在最坏情况下，为$O\left(m\cdot n^2\right)$，其中m是任务的数量，n是工人的数量。其空间复杂度为$O\left(n+m\right)$，用于存储工人和任务的信息，以及中间计算结果。在分布式环境中，其通信复杂度为$O\left(m\cdot n\right)$，而在集中式环境中，因为所有计算都在中心服务器上进行，通信复杂度仅为$O\left(1\right)$。

4　实验分析

4.1 数据集

实验采用2个真实数据集：TKY和NYC签到数据集[25]。TKY包含约57万条记录，NYC包含约22万条记录。实验中，TKY和NYC均选取50个办公室地址作为任务位置，其中TKY对应500个地铁地址作为工人位置，NYC对应300个地铁地址作为工人位置。每项任务被分配5～10种技能，而每个工人拥有1～5种技能。任务预算范围为100～1000，工人单价与其技能数量相关。

4.2 评价指标

首先，探讨隐私保护机制对服务质量损失(Loss of Quality of Service, LQS)的影响。LQS由真实位置与模糊位置之间的偏差衡量，其大小直接影响任务分配的准确性和效率，式中的$\mathcal{M}$为任务总数。

$$\mathrm{LQS}=\mathrm{RMSE}=\sqrt{\frac{\sum_{i=1}^{N}\left(l'_i(p)-l_i(p)\right)^2}{\mathcal{M}}} \tag{21}$$

其次，分析有无二次筛选策略下熵值$H(t_j)$(式(5))变化以及经过二次筛选策略后任务分配过程中技能贡献值$\Delta\mathcal{S}_i$(式(13))的选择变化。

最后，定义平均预算剩余率(Average Remaining Budget Rate, ARBR)来反映目标函数的求解效果，其中M为成功分配的任务数量。同时探讨隐私保护机制对任务完成率(Task Completion Rate, TCR)的影响，较高的任务完成率表明所采用的分配策略能够有效匹配工人和任务。

$$\mathrm{ARBR}=\left(\frac{\mathcal{B}'}{\mathcal{B}_j}\right)\Big/M \tag{22}$$

$$\mathrm{TCR}=\frac{M}{\mathcal{M}} \tag{23}$$

4.3 对比算法

为验证本文所提算法的有效性，现将任务分配算法PUGR分别在TKY和NYC数据集上与以下算法进行对比实验。

(1)Greedy：以工人能否贡献任务尚未覆盖的技能为依据，每次迭代优先选择满足条件的工人，且无剪枝策略。

(2)OE-ELA[18]：对于任务所需的每项技能，先收集掌握该技能的工人集合，再计算所有工人集合的笛卡儿积，枚举所有可能的分配方案，最终选择工人报酬最高的方案。

(3)TsPY[19]：采用先时间后空间的方式构建任务层次树，结合并行计算和深度优先搜索算法，按照短距离优先原则分配任务。

(4)NoPriv：在已知工人真实位置的前提下，直接利用PUGR, GR, OE-ELA和TsPY求解。

(5)CLP：在工人位置通过截断拉普拉斯机制扰动后，利用PUGR,GR,OE-ELA和TsPY求解。

(6)LP：在工人位置通过拉普拉斯机制扰动后，利用PUGR, GR, OE-ELA和TsPY求解。

本文所有算法均在一台Intel Core i5-8250U、4核8线程的笔记本电脑上，采用Python 3.8实现。

4.4 实验结果

从图2可见，截断拉普拉斯机制CLP与拉普拉斯机制LP下，LQS均随ε增大而下降，即噪声减小后位置偏差降低，服务质量损失缩小。相比LP, CLP在不同数据集上始终表现更优，因其能有效控制噪声范围，避免极端误差，从而在保障隐私的同时提升位置数据实用性，为任务分配提供更高可靠性。这一结果验证了CLP在隐私保护与实用性平衡方面的优势。

图3展示了二次筛选策略在任务分配中的作用效果。通过实验评估，熵值为0.55为经验性最优值，该阈值亦可根据不同应用场景进行自适应调整。由图3(a)可见，当任务工人集合的熵值低于阈值0.55时，二次筛选使得工人技能集合的种类趋于均衡，避免因技能稀缺而导致远距离工人被选用，从而降低预算消耗。进一步地，图3(b)表明，经过二次筛选的工人集合，其技能贡献值普遍不低于0.4，即便在初始阶段也能有效覆盖所需技能。当技能贡献值$\Delta\mathcal{S}_i$为1时，意味任务分配完成，且迭代次数不超过4次。这说明二次筛选策略不仅优化了技能分布结构，还减少了冗余计算，提升了PUGR算法的运行效率。

图4展示了在不同隐私保护机制(CLP与LP)下，PUGR, GR, OE-ELA和TsPY算法随隐私预算ε变化而变化的平均预算剩余率ARBR，并与无隐私保护机制NoPriv进行了对比。

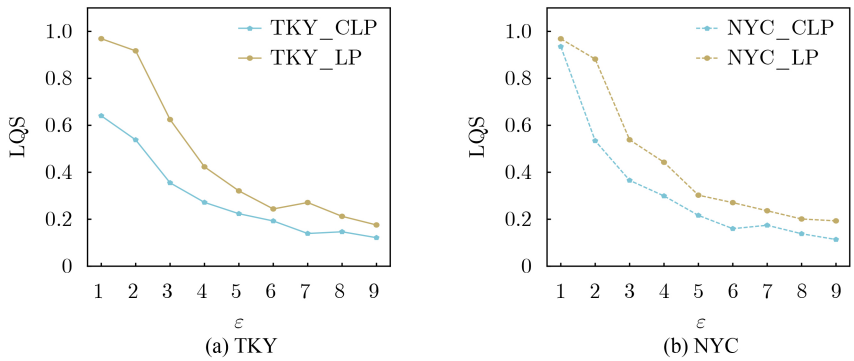

(a) TKY (b) NYC

图 2 TKY和NYC上的服务质量损失

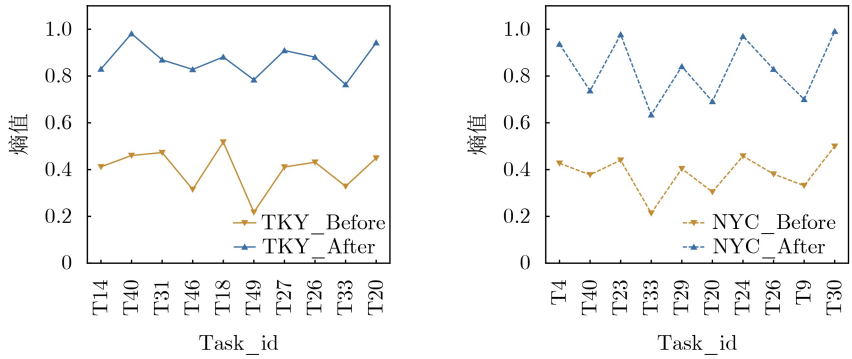

(a) TKY和NYC上的熵值变化

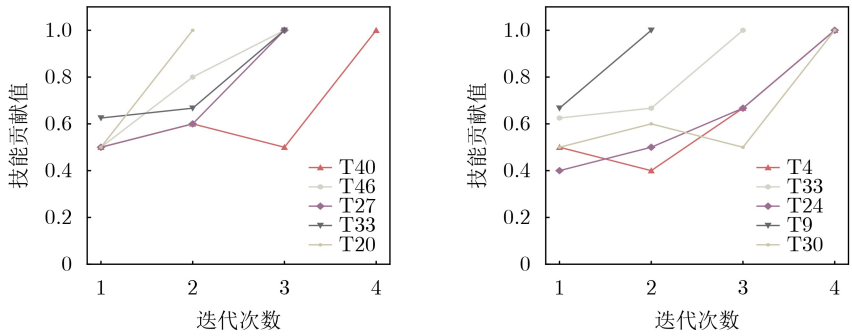

(b) TKY和NYC上技能贡献值变化

图 3 熵值和技能贡献值变化

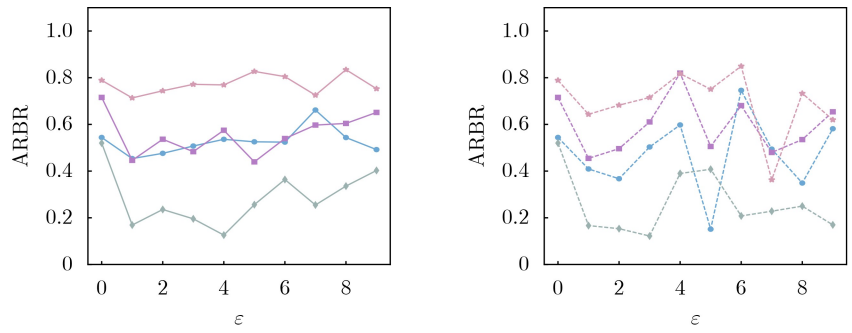

(a) 隐私预算对TKY上平均预算剩余率的影响

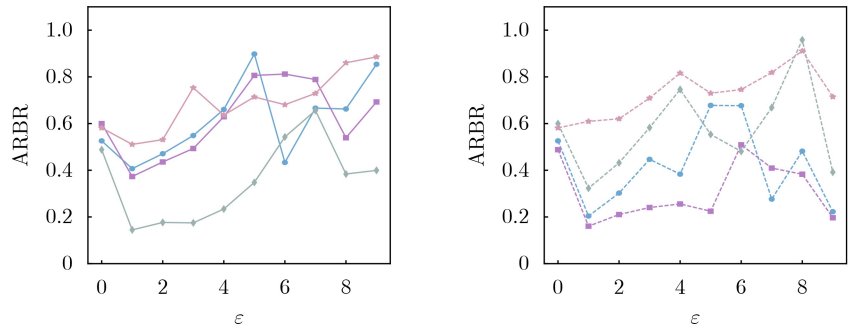

(b) 隐私预算对NYC上平均预算剩余率的影响

图 4 不同数据集上隐私预算对平均预算剩余率的影响

结合表2部分实验数据可见，随着隐私预算ε的增大，4种任务分配算法的ARBR逐渐接近NoPriv，其中PUGR在各数据集下表现最佳，且在CLP下更接近NoPriv。此外，相较于LP, CLP能够生成更稳

定的模糊位置数据，避免了噪声无界性带来的预算偏差，从而在保证隐私的同时提升了任务分配的经济效益。

图5展示了在不同隐私机制下，PUGR, GR, OE-ELA和TsPY4种任务分配算法在TKY和NYC数据集上的TCR随隐私预算ε的变化情况。结果表明，随着ε的增大，各项算法的TCR均呈现稳步上升趋势，并逐渐接近NoPriv，其中PUGR始终保持最高，NoPriv下的TCR可达90%。同时，CLP下的TCR普遍高于LP，原因在于LP的过度加噪会导致任务分配失败，而CLP通过限制扰动范围有效避免了极端值，从而提升了分配的可靠性。另一个现象是，TKY数据集上的TCR普遍高于NYC，表明工人资源的充足显著提升了任务完成率，而在此条件下PUGR的优势更为明显。

5 结束语

本研究提出了一种融合隐私保护与技能优化的空间众包任务分配框架。在隐私保护方面，采用截断拉普拉斯机制对工人位置信息进行扰动，以有效

表 2 不同数据集上隐私预算对平均预算剩余率的影响

数据集	ε	ARBR							
		PUGR		GR		OE-ELA		TsPY	
		CLP	LP	CLP	LP	CLP	LP	CLP	LP
TKY	0	0.7890		0.5200		0.7156		0.5441	
	1	0.7135	0.6431	0.1689	0.1666	0.4460	0.4545	0.4536	0.4091
	3	0.7716	0.7153	0.1956	0.1219	0.4832	0.6106	0.5074	0.5033
	5	0.8269	0.7505	0.2562	0.4079	0.4395	0.5055	0.5254	0.1512
NYC	0	0.5813		0.4881		0.5998		0.5259	
	1	0.5108	0.6095	0.1447	0.1604	0.3731	0.3231	0.4070	0.2039
	3	0.7535	0.7091	0.1747	0.2404	0.4932	0.5826	0.5487	0.4468
	5	0.7141	0.7300	0.3479	0.2246	0.8063	0.5535	0.8979	0.6780

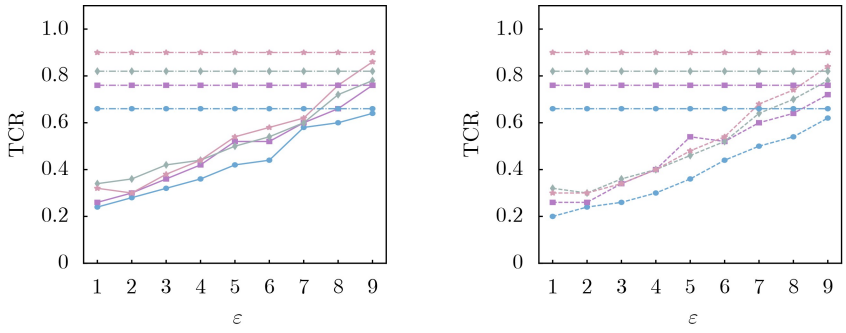

(a) 隐私预算对TKY上任务完成率的影响

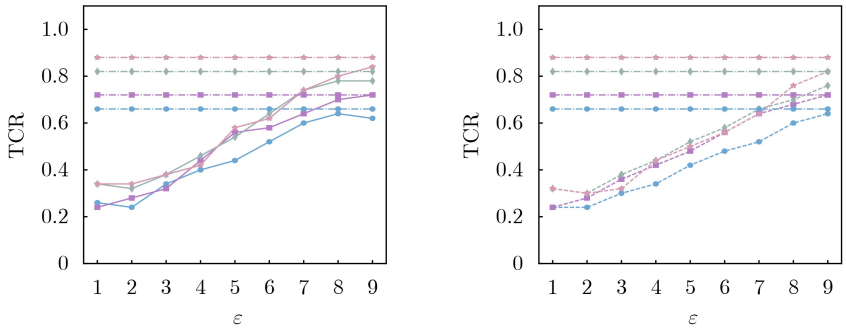

(b) 隐私预算对NYC上任务完成率的影响

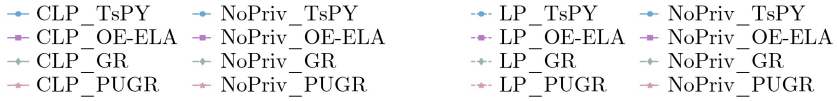

图 5 不同数据集上隐私预算对任务完成率的影响

控制噪声范围，减少位置扰动带来的数据偏差。针对技能分布不均衡问题，创新性地引入信息熵作为评估指标，并设计动态调整机制优化工人集合技能构成。在算法设计上，提出基于贪心策略的高效分配方法，结合剪枝技术显著提升了计算效率。实验结果表明，该框架在保证隐私安全的前提下，能够有效提升任务分配的成功率和效率。未来研究可进一步探索基于技能稀缺度的动态定价机制，以及更具个性化与适应性的激励策略，以促进任务分配的公平性和可持续性。

参 考 文 献

[1] XIE Yuan, WANG Yongheng, LI Kenli, *et al*. Satisfaction-aware task assignment in spatial crowdsourcing[J]. *Information Sciences*, 2023, 622: 512–535. doi: 10.1016/j.ins.2022.11.081.

[2] XU Lang, LI Jiqiang, ZHANG Hao, *et al*. A privacy-preserving takeaway delivery service scheme[C]. 17th International Conference on Provable and Practical Security, Wuhan, China, 2023: 385–403. doi: 10.1007/978-3-031-45513-1_21.

[3] 孟秀丽, 杨静, 吴一凡. 考虑奖惩机制和成本互担的众包物流服务质量最优控制[J]. 中国管理科学, 2022, 30(11): 182–195. doi: 10.16381/j.cnki.issn1003-207x.2020.0746.

MENG Xiuli, YANG Jing, and WU Yifan. Optimal control of crowdsourcing logistics service quality considering reward-penalty mechanism and cost sharing[J]. *Chinese Journal of Management Science*, 2022, 30(11): 182–195. doi: 10.16381/j.cnki.issn1003-207x.2020.0746.

[4] LIN Ping, ZHANG Xiaosan, YAN Shuming, *et al*. Dynamic capabilities and business model innovation of platform enterprise: A case study of DiDi taxi[J]. *Scientific Programming*, 2020, 2020(1): 8841368. doi: 10.1155/2020/8841368.

[5] WANG Jianqiang, PAN Jialu, ZHENG Liping, *et al*. A systematic space-time route planning approach coordinated with task assignment for autonomous delivery vehicles fleet[J]. *IEEE Access*, 2023, 11: 79370–79383. doi: 10.1109/ACCESS.2023.3299856.

[6] GUO Bin, LIU Yan, WANG Leye, *et al*. Task allocation in spatial crowdsourcing: Current state and future directions[J]. *IEEE Internet of Things Journal*, 2018, 5(3): 1749–1764. doi: 10.1109/JIOT.2018.2815982.

[7] 冯登国, 张敏, 叶宇桐. 基于差分隐私模型的位置轨迹发布技术研究[J]. 电子与信息学报, 2020, 42(1): 74–88. doi: 10.11999/JEIT190632.

FENG Dengguo, ZHANG Min, and YE Yutong. Research on differentially private trajectory data publishing[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 74–88. doi: 10.11999/JEIT190632.

[8] NAVIDAN H, MOGHTADAIEE V, NAZARAN N, *et al*. Hide me behind the noise: Local differential privacy for indoor location privacy[C]. 2022 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW), Genoa, Italy, 2022: 514–523. doi: 10.1109/EuroSPW55150.2022.00061.

[9] ZHANG Pengfei, FANG Xiang, ZHANG Zhikun, *et al*. Horizontal multi-party data publishing via discriminator regularization and adaptive noise under differential privacy[J]. *Information Fusion*, 2025, 120: 103046. doi: 10.1016/j.inffus.2025.103046.

[10] 李可佳, 胡学先, 陈越, 等. 基于主成分分析和函数机制的差分隐私线性回归算法[J]. 计算机科学, 2023, 50(8): 342–351. doi: 10.11896/jsjkx.220800255.

LI Kejia, HU Xuexian, CHEN Yue, *et al*. Differential privacy linear regression algorithm based on principal component analysis and Functional mechanism[J]. *Computer Science*, 2023, 50(8): 342–351. doi: 10.11896/jsjkx.220800255.

[11] ZHANG Pengfei, CHENG Xiang, ZHANG Zhikun, *et al*. Maximizing area coverage in privacy-preserving worker recruitment: A prior knowledge-enhanced geo-indistinguishable approach[J]. *IEEE Transactions on Information Forensics and Security*, 2025, 20: 5138–5151. doi: 10.1109/TIFS.2025.3568163.

[12] ZHANG Pengfei, SUN Hong, ZHANG Zhikun, *et al*. Privacy-preserving recommendations with mixture model-based matrix factorization under local differential privacy[J]. *IEEE Transactions on Industrial Informatics*, 2025, 21(7): 5451–5459. doi: 10.1109/TII.2025.3555993.

[13] LIU Yixuan, ZHAO Suyun, XIONG Li, *et al*. Echo of neighbors: Privacy amplification for personalized private federated learning with shuffle model[C]. The 37th AAAI Conference on Artificial Intelligence, Washington, USA, 2023: 11865–11872. doi: 10.1609/aaai.v37i10.26400.

[14] 吴大鹏, 管芃, 张普宁, 等. 群组协作的移动群智感知任务分配方法[J]. 电子与信息学报, 2023, 45(12): 4308–4316. doi: 10.11999/JEIT221046.

WU Dapeng, GUAN Peng, ZHANG Puning, *et al*. Task allocation method of mobile crowdsensing based on group collaboration[J]. *Journal of Electronics & Information Technology*, 2023, 45(12): 4308–4316. doi: 10.11999/JEIT221046.

[15] HUANG Yang, CHEN Honglong, MA Guoqi, *et al*. OPAT: Optimized allocation of time-dependent tasks for mobile crowdsensing[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2476–2485. doi: 10.1109/TII.2021.3094527.

[16] LIU Jiaxu, ZHU Haogang, and CHEN Xiao. Complicated-

skills-based task assignment in spatial crowdsourcing[C]. WAIM 2016 International Workshops on Web-Age Information Management, Nanchang, China, 2016: 211–223. doi: 10.1007/978-3-319-47121-1_18.

[17] TAO Xi and HAFID A S. DeepSensing: A novel mobile crowdsensing framework with double deep *Q*-network and prioritized experience replay[J]. *IEEE Internet of Things Journal*, 2020, 7(12): 11547–11558. doi: 10.1109/JIOT.2020.3022611.

[18] SONG Tianshu, XU Ke, LI Jiangneng, *et al*. Multi-skill aware task assignment in real-time spatial crowdsourcing[J]. *Geoinformatica*, 2020, 24(1): 153–173. doi: 10.1007/s10707-019-00351-4.

[19] HAN Lei, YU Zhiwen, YU Zhiyong, *et al*. Online organizing large-scale heterogeneous tasks and multi-skilled participants in mobile crowdsensing[J]. *IEEE Transactions on Mobile Computing*, 2023, 22(5): 2892–2909. doi: 10.1109/tmc.2021.3132616.

[20] HONG Yingcong, LI Junyi, LIN Yaping, *et al*. Trajectory-aware privacy-preserving method with local differential privacy in crowdsourcing[J]. *EURASIP Journal on Information Security*, 2024, 2024(1): 28. doi: 10.1186/s13635-024-00177-0.

[21] WEI Jianhao, LIN Yaping, YAO Xin, *et al*. Differential privacy-based location protection in spatial crowdsourcing[J]. *IEEE Transactions on Services Computing*, 2022, 15(1): 45–58. doi: 10.1109/TSC.2019.2920643.

[22] WANG Leye, YANG Dingqi, HAN Xiao, *et al*. Mobile crowdsourcing task allocation with differential-and-distortion geo-obfuscation[J]. *IEEE Transactions on Dependable and Secure Computing*, 2021, 18(2): 967–981. doi: 10.1109/TDSC.2019.2912886.

[23] BÉZIAUD L, ALLARD T, GROSS-AMBLARD D, *et al*. Lightweight privacy-preserving task assignment in skill-aware crowdsourcing[C]. 28th International Conference on Database and Expert Systems Applications, Lyon, France, 2017: 18–26. doi: 10.1007/978-3-319-64471-4_2.

[24] VAZIRANI V V. Approximation Algorithms[M]. Berlin: Springer, 2003: 1–380. doi: 10.1007/978-3-662-04565-7.

[25] YANG Dingqi, ZHANG Daqing, ZHENG V W, *et al*. Modeling user activity preference by leveraging user spatial temporal characteristics in LBSNs[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2015, 45(1): 129–142. doi: 10.1109/tsmc.2014.2327053.

方贤进：男，教授，研究方向为网络与信息安全、智能计算.
甄雅茹：女，硕士生，研究方向为数据隐私保护.
张朋飞：男，讲师，研究方向为数据隐私保护.
黄珊珊：女，硕士生，研究方向为群智感知、隐私保护.

责任编辑：廖海贝

Research on Skill-Aware Task Assignment Algorithm under Local Differential Privacy

FANG Xianjin[①②] ZHEN Yaru[①] ZHANG Pengfei[①②] HUANG Shanshan[①]

[①](*Department of Computer Science and Engineering, Anhui University of Science and Technology, Huainan* 232001, *China*)

[②](*State Key Laboratory of Digital Intelligent Technology for Unmanned Coal Mining, Anhui University of Science and Technology, Huainan* 232001, *China*)

Abstract:

Objective With the proliferation of mobile smart devices and wireless networks, Spatial Crowdsourcing (SC) has emerged as a new paradigm for collaborative task execution. By leveraging workers' real-time locations, SC platforms dynamically assign tasks to distributed participants. However, continuous exposure of location data creates privacy risks, including trajectory inference and identity disclosure, which reduce worker participation and threaten system sustainability. Existing privacy-preserving methods either rely on trusted third parties or apply traditional differential privacy mechanisms. The former incurs high costs and security vulnerabilities, whereas the latter struggles to balance the trade-off between noise magnitude and data utility, often reducing task matching accuracy. To address these challenges, this study proposes a skill-aware task assignment algorithm under Local Differential Privacy (LDP) that simultaneously enhances location privacy protection and task assignment performance. The algorithm is particularly effective in settings characterized by uneven skill distributions and complex task requirements.

Methods　To protect workers' location privacy, a Clip-Laplace (CLP) mechanism is applied to perturb real-time location data under Local Differential Privacy (LDP), ensuring bounded noise while maintaining data utility. To mitigate mismatches between heterogeneous task requirements and imbalanced worker skills, an entropy-based metric is used to evaluate skill diversity. When entropy falls below a predefined threshold, a secondary screening strategy rebalances the distribution by suppressing common skills and prioritizing rare ones. A skill-aware Pruning Greedy task assignment algorithm (PUGR) is then developed. PUGR iteratively selects the worker-task pair with the highest marginal contribution to maximize skill coverage under spatiotemporal and budget constraints. To improve computational efficiency, three pruning strategies are integrated: time-distance pruning, high-reward pruning, and budget-infeasibility pruning. Finally, comparative and ablation experiments on three real-world datasets assess the method using multiple metrics, including Loss of Quality of Service (LQS), Average Remaining Budget Rate (ARBR), and Task Completion Rate (TCR).

Results and Discussions　Experimental results show that the CLP mechanism consistently achieves lower LQS than the traditional Laplace mechanism (LP) across different privacy budgets, effectively reducing errors introduced by noise (Fig. 2). For skill diversity, the entropy-based metric combined with secondary screening nearly doubles the average entropy of candidate workers on the TKY and NYC datasets, demonstrating its effectiveness in balancing skill distribution. In task assignment, the proposed PUGR algorithm completes most worker-task matchings within four iterations, thereby reducing redundant computation and accelerating convergence (Fig. 3). Regarding budget utilization, the ARBR under CLP remains close to the No Privacy (NoPriv) baseline, indicating efficient resource allocation (Fig. 4, Table 2). For task completion, the method achieves a TCR of up to 90% in noise-free settings and consistently outperforms Greedy, OE-ELA, and TsPY under CLP (Fig. 5). Ablation studies further validate the contributions of secondary screening and pruning strategies to overall performance improvement.

Conclusions　This study addresses two central challenges in spatial crowdsourcing: protecting workers' location privacy and improving skill-aware task assignment. A task assignment framework is proposed that integrates the CLP mechanism with a skill-aware strategy under the LDP model. The CLP mechanism provides strong privacy guarantees while preserving data utility by limiting noise magnitude. An entropy-based metric combined with secondary screening ensures balanced skill distribution, substantially enhancing skill coverage and task execution success in multi-skill scenarios. The PUGR algorithm incorporates skill contribution evaluation with multiple pruning constraints, thereby reducing the search space and improving computational efficiency. Experiments on real-world datasets demonstrate the method's superiority in terms of LQS, ARBR, and TCR, confirming its robustness, scalability, and effectiveness in balancing privacy protection with assignment performance. Future work will explore dynamic pricing mechanisms based on skill scarcity and personalized, adaptive incentives to foster fairness, long-term worker engagement, and the sustainable development of spatial crowdsourcing platforms.

Key words: Spatial crowdsourcing; Task assignment; Local Differential Privacy (LDP); Skill diversity; Greedy algorithm