

## 基于预测和滑动窗口的轨迹差分隐私保护机制

叶阿勇<sup>1,2</sup>, 孟玲玉<sup>1,2</sup>, 赵子文<sup>1,2</sup>, 刁一晴<sup>1,2</sup>, 张娇美<sup>1,2</sup>

(1. 福建师范大学数学与信息学院, 福建 福州 350007; 2. 福建省网络安全与密码技术重点实验室, 福建 福州 350007)

**摘要:** 为解决轨迹差分隐私保护中存在的隐私预算与服务质量等问题, 提出了一种融合预测扰动的轨迹差分隐私保护机制。首先, 利用马尔可夫链和指数扰动方法预测满足差分隐私和时空安全的扰动位置, 并引入服务相似地图检测该位置的可用性; 如果预测成功, 则直接采用预测位置替代差分扰动的位置, 以降低连续查询的隐私开销并提高服务质量。在此基础上, 设计基于  $w$  滑动窗口的轨迹隐私预算分配机制, 确保轨迹中任意连续的  $w$  次查询满足  $\epsilon$ -差分隐私, 解决连续查询的轨迹隐私问题。此外, 基于敏感度地图设计一种隐私定制策略, 通过自定义语义位置的隐私敏感度, 实现隐私预算的量身定制, 从而进一步提高其利用率。最后, 利用真实数据集对所提方案进行实验分析, 结果显示所提方案提供了更好的隐私保护水平和服务质量。

**关键词:** 位置隐私; 轨迹隐私; 差分隐私; 隐私累积

**中图分类号:** TP309.2

**文献标识码:** A

**doi:** 10.11959/j.issn.1000-436x.2020049

## Trajectory differential privacy protection mechanism based on prediction and sliding window

YE Ayong<sup>1,2</sup>, MENG Lingyu<sup>1,2</sup>, ZHAO Ziwen<sup>1,2</sup>, DIAO Yiqing<sup>1,2</sup>, ZHANG Jiaomei<sup>1,2</sup>

1. College of Mathematics and Informatics, Fujian Normal University, Fuzhou 350007, China

2. Fujian Provincial Key Laboratory of Network Security and Cryptology, Fuzhou 350007, China

**Abstract:** To address the issues of privacy budget and quality of service in trajectory differential privacy protection, a trajectory differential privacy mechanism integrating prediction disturbance was proposed. Firstly, Markov chain and exponential perturbation method were used to predict the location which satisfies the differential privacy and temporal and spatial security, and service similarity map was introduced to detect the availability of the location. If the prediction was successful, the prediction location was directly used to replace the location of differential disturbance, to reduce the privacy cost of continuous query and improve the quality of service. Based on this, the trajectory privacy budget allocation mechanism based on  $w$  sliding window was designed to ensure that any continuous  $w$  queries in the trajectory meet the  $\epsilon$ -differential privacy and solve the trajectory privacy problem of continuous queries. In addition, a privacy customization strategy was designed based on the sensitivity map. By customizing the privacy sensitivity of semantic location, the privacy budget could be customized to improve its utilization. Finally, the validity of the scheme was verified by real data set experiment. The results illustrate that it offers the better privacy and quality of service.

**Key words:** location privacy, trajectory privacy, differential privacy, privacy accumulation

### 1 引言

近几年来, 随着具有定位功能的智能终端和移

动通信技术的迅猛发展, 各种基于位置的服务(LBS, location based service)日益普及, 现已覆盖国民经济和社会生活的方方面面, 如导航、兴趣点查询与

收稿日期: 2019-10-21; 修回日期: 2020-01-30

基金项目: 国家自然科学基金资助项目 (No.61972096, No.61872088, No.61872090); 福建省自然科学基金资助项目 (No.2018J01780)

**Foundation Items:** The National Natural Science Foundation of China (No.61972096, No.61872088, No.61872090), The Natural Science Foundation of Fujian Province (No.2018J01780)

推荐、外卖、签到、社交网络等<sup>[1]</sup>。然而，LBS 为人们的日常生活带来极大便利的同时，也产生了位置隐私泄露问题。其中尤其突出的是，位置服务提供商可能会利用数据挖掘等技术，从用户提交的位置信息中非法获取用户的敏感信息，如家庭/工作地址、消费水平、健康状况、生活习惯等<sup>[2]</sup>。

地理不可区分性<sup>[3]</sup>隐私保护模型是目前 LBS 位置隐私保护中常见的方法，它将差分隐私<sup>[4]</sup>引入几何空间中，克服了传统  $k$ -匿名等模型普遍存在“依赖于攻击者背景知识而导致其安全性无法严格证明”的缺点。地理不可区分性模型是通过极坐标系下的 Laplace 扰动机制向用户位置添加受控噪声，使攻击者几乎无法区分近似位置与真实位置的差异，从而将用户真实位置保护在一个半径为  $r$  的圆形区域内。位置差分隐私的定义是建立在严格数学统计模型上，并可通过调整隐私参数来控制隐私保护水平，因此备受关注。然而，现有的位置差分隐私保护研究仍然存在以下两方面的问题。

1) 现有的位置差分保护机制仅适用于单次或零星查询，多次查询仍有可能暴露用户的真实位置。因为连续查询的位置间存在时空相关性，服务查询不仅会消耗当前位置的隐私成本，而且也会增加其他位置的隐私消耗，即差分隐私具有序列组合特性。因此，单个位置满足  $\epsilon$ -差分隐私，并不能确保轨迹满足  $\epsilon$ -差分隐私。

2) 现有的差分隐私保护技术并没有很好地解决隐私风险与服务质量的矛盾问题；位置差分隐私中，每个扰动的位置输出具有一定的随机性，隐私预算越小，隐私保护程度越高，但是该位置的服务质量会越差。隐私风险与服务质量的矛盾，难以得到平衡。

位置预测是指通过观察已公开的信息（如历史发布的轨迹）来预测用户当前的位置。由于预测机制与用户当前的真实位置无关，不会给攻击者提供更多有用信息，因此隐私损失非常小，甚至可视为 0。因此本文尝试利用预测机制替代差分扰动，以节省隐私开销，即降低隐私风险。基于上述分析，本文提出一种基于预测和滑动窗口的轨迹差分隐私保护机制，主要贡献如下。

1) 提出一种融合预测扰动的差分查询机制，以降低连续查询的隐私开销。首先，利用马尔可夫链和指数扰动机制预测满足差分安全和时空相关性约束的查询位置。然后，引入服务相似地图机制检

测预测位置的可用性，如果满足可用性要求，则采用预测位置查询，否则使用差分扰动的位置查询。

2) 设计基于  $w$  滑动窗口的轨迹隐私预算分配机制，确保轨迹中任意连续的  $w$  次查询隐私消耗累计不超过  $\epsilon$ ，即确保轨迹满足  $\epsilon$ -差分隐私，从而解决连续查询的位置隐私安全问题。

3) 设计基于敏感度地图的位置隐私差异化保护机制。通过允许用户自定义位置的敏感度，实现隐私预算的量身定制，进一步提高隐私预算的利用率。

4) 利用真实数据集对本文方案进行实验分析，验证方案的有效性。

## 2 相关工作

在过去的几年中，研究者已提出许多的位置隐私保护方案和技术。根据保护机理的不同，本文将分为匿名和扰动两大类。

$k$ -匿名<sup>[5]</sup>是目前最被广泛应用的位置隐私保护机制。其思想是采用一个包含至少  $k-1$  个用户的区域来替代用户的实际位置，用于向 LBS 请求服务。在该定义中，用户的身份至少与  $k-1$  个人不可区分，从而有效地解决不可信服务器带来的身份隐私泄露问题。例如，Niu 等<sup>[6]</sup>提出了一种虚拟位置选择算法来实现 LBS 中用户的  $k$ -匿名性。Hwang 等<sup>[7]</sup>提出了一种基于历史轨迹的时间模糊算法。在该算法中，TTP 在选定  $k-1$  条历史轨迹后，扰动每个查询轨迹的时间序列，产生空间和时间的双重混淆。Wang 等<sup>[8]</sup>对位置  $k$ -匿名的有效解决方案进行了研究，并定义了一种用于初始化位置  $k$ -匿名的概率模型 PkA(probabilistic  $k$ -anonymity framework)，也证明了 DLS (dummy-location selection) 算法属于 PkA。

位置扰动是指用户请求 LBS 时，以假位置替代或者混合自身的真实位置，从而保护位置隐私。例如，文献[9]提出一种基于假查询的连续位置服务隐私保护机制，该机制根据邻居节点的运动速率和方向预测将来的轨迹；在此基础上，选出轨迹与查询用户相近的  $k-1$  个邻居节点；在匿名处理时，通过发动这些邻居节点插入假查询，来构造虚假的连续查询。Andres 等<sup>[3]</sup>基于差分隐私的思想提出了地理不可区分性的位置隐私模型，并设计了一种极坐标系下的 Laplace 机制产生假位置，以实现位置隐私保护。文献[10]在文献[3]的基础上将差分隐私机制看成是最优化问题，提出了一种基于  $\delta$ -spanner 的近似解决方案。Xiao 等<sup>[11]</sup>用马尔可夫链表示位置上的时

序关系，并重新定义相邻数据集的概念，提出了一种基于凸包的差分隐私位置发布机制。Hua等<sup>[12]</sup>提出了在短时间连续查询时，基于差分隐私的位置隐私保护方法，解决了连续查询时隐私风险与查询次数成线性增长的问题。吴云乘等<sup>[13]</sup>基于马尔可夫概率转移矩阵，分析了发布位置对当前真实位置和之前真实位置的影响，提出了一种差分隐私位置发布机制(DPLRM, privacy location release mechanism)，以保护用户的位置和轨迹隐私。Chatzikokolakis等<sup>[14]</sup>提出一种预测扰动机制(PM, predictive mechanism for mobility trace)，利用预测位置替代真实位置，解决连续查询的隐私与可用性的两难问题。

### 3 背景知识

#### 3.1 位置差分隐私

**定义 1**  $\epsilon$ -差分隐私。 $\forall x, x' \in X$ ，在查询机制  $M$  下输出的位置  $o$ ，若满足式(1)，则称算法  $M$  满足  $\epsilon$ -差分隐私

$$M(x)(o) \leq e^{cd_x(x,x')} M(x')(o) \quad (1)$$

其中， $M(x)(o)$ 为原始输入  $x$  在扰动机制  $M$  下输出结果为  $o$  的概率，该定义表明 2 个原始输入越接近，则输出同一位置的概率越高，即 2 个源位置不可区分，从而达到保护用户位置隐私的目的； $\epsilon$  为一个距离单位的隐私预算，代表隐私保护的程度， $\epsilon$  越小，隐私保护程度越高，当  $\epsilon=0$  时，隐私保护程度最高，表示没有泄露用户的任何隐私。

$d_x(x, x')$ 是测量矩阵，不同的  $d_x(x, x')$ 模型可以解决不同应用场景的差分隐私问题。如数据库查询隐私保护模型中<sup>[4]</sup>， $d_x(x, x')=1$  表示 2 个统计数据库  $x$  和  $x'$ 仅相差一条纪录。该模型保证数据集中增加和删除任意一条记录都不会影响输出的结果，即无法得知数据集中是否存在某条记录，从而达到保护数据隐私的目的。该定义只是理论上一个模型，而要实现具体的保护则需要噪声机制的介入。对于数值型数据和非数值型数据，主要的噪声机制分别为 Laplace 扰动机制和指数扰动机制，具体说明如下。

**定义 2** Laplace 扰动。对于数据集  $D$  上的任意一个函数  $f: D \rightarrow R^d$ ，若函数  $f$  的输出结果满足式(2)，则  $f$  满足  $\epsilon$ -差分隐私。

$$M(D) = f(D) + \text{Lap}\left(\frac{\Delta f}{\epsilon}\right)^d \quad (2)$$

其中， $\Delta f$  为查询函数的敏感度。Laplace 分布的位

置参数为 0，尺度参数为  $\frac{\Delta f}{\epsilon}$ 。

**定义 3** 指数扰动。给定一个可用函数  $f: (D^n \times R) \rightarrow \Omega$ ， $r$  是可用函数输出域 range 中的一个实体对象，若函数  $f$  的输出结果满足式(3)，则  $f$  满足  $\epsilon$ -差分隐私。

$$M(D, f) = \{r: \Pr[r \in \text{Range}] \propto \exp\left(\frac{\epsilon f(D, r)}{2S(f)}\right)\} \quad (3)$$

其中， $S(f)$ 为可用函数的全局敏感度，对象被选中的概率正比于可用函数  $f$  的打分。指数机制以正比于  $\exp\left(\frac{\epsilon f(D, r)}{2S(f)}\right)$  的概率返回实体对象。

若  $d_x(x, x')=d_2(x, x')$ ，则代表 2 个地理位置间的欧氏距离，此时该模型可用于保护 LBS 位置查询时的隐私泄露问题，本文称其为  $\epsilon$ -地理不可区分性，该定义等价于欧氏距离空间中的  $\epsilon$ -差分隐私。

**定义 4**  $\epsilon$ -地理不可区分性<sup>[3]</sup>。对于任意满足  $d_2(x, x') \leq r$  的 2 个位置  $x$  和  $x'$ ，若在查询机制  $M$  下输出的位置集  $o$  满足式(4)，则称  $M$  满足  $\epsilon$ -地理不可区分性。

$$M(x)(o) \leq e^{cd_x(x,x')} M(x')(o) \quad (4)$$

其中， $M(x)(o)$ 是在查询机制  $M$  中，位置  $x$  输出位置  $o$  的概率。 $\epsilon$  为一个距离单位的隐私预算，则任意半径  $r$  的隐私预算为  $\epsilon=er$ ，此时用户的真实位置被保护在半径为  $r$  的圆中。可以看出，2 个位置的地理距离越近，生成相同查询位置  $o$  的概率越相似，地理位置越不可区分，隐私保护程度越高。进一步，利用其极坐标下的 Laplace 机制产生满足  $\epsilon$ -地理不可区分性的噪声位置（假的查询位置），实现该模型的隐私保护。

此外， $\epsilon$ -差分隐私具有序列组合特性，即如果每个发布机制  $M_i$  满足  $\epsilon_i$ -差分隐私，则  $M_i$  的一个序列应用则满足  $\sum \epsilon_i$ -差分隐私。此性质指出，当查询机制应用  $n$  次 LBS 查询服务时，每个噪声位置的隐私预算为  $\epsilon$ ，则轨迹的隐私预算为  $n\epsilon$ 。

**定义 5**  $w$  连续序列  $\epsilon$ -差分隐私。假设用户的轨迹为  $Z=\{z_1, z_2, z_3, \dots, z_n\}$ ，其中  $z_i$  为在查询机制  $M_i$  下输出的假查询位置，并且  $M_i$  满足  $\epsilon_i$ -差分隐私。对于其中任意一个  $w$  个时间戳的连续位置序列子集  $\{z_{i-w+1}, \dots, z_i\}$ ，若其隐私预算之和满足式(5)，则用户的轨迹隐私满足  $w$  连续序列  $\epsilon$ -差分隐私。

$$\forall i \in [t], \sum_{k=i-w+1}^i \varepsilon_k \leq \varepsilon \quad (5)$$

**定义 6**  $\delta$ -位置集<sup>[11]</sup>。假设用户在  $t$  时刻有  $n$  个可能的位置, 令  $\mathbf{Q}^{(t)} = \{q_1^{(t)}, \dots, q_n^{(t)}\}$  表示用户在各个位置的的概率值, 则  $\delta$ -位置集为累积概率值不少于  $1-\delta$  的最小位置集, 即

$$\Delta X_t = \min \left\{ q_i^{(t)} \left| \sum_{q_i^{(t)}} \mathbf{Q}^{(t)}[i] \geq 1 - \delta \right. \right\} \quad (6)$$

直观而言,  $\delta$ -位置集是用于删除可能位置集中概率比较低的位置点。

### 3.2 相似地图

LBS 中, 用户通过向服务提供商提供自身位置获取相关服务。但是由于地理位置的空间特征, 不同位置的查询结果可能是相同或相似的。因此定义服务相似度, 具体如下。

**定义 7** 位置的服务相似度<sup>[15]</sup>。假设有 2 个位置  $g$  和  $h$ , 则它们的服务相似度定义为

$$S = \text{sim}(g, h) = \text{sim}((x_g, y_g), (x_h, y_h)) = \frac{|R_k(x_g, y_g) \cap R_k(x_h, y_h)|}{k}, 0 \leq S \leq 1 \quad (7)$$

其中,  $(x_i, y_i)$  是位置  $i$  的坐标,  $R_m(x, y)$  是在坐标  $(x, y)$  处查询的 top- $m$  个兴趣点的排序结果集,  $|\cdot|$  是集合元素的数量。

通过服务相似度对地图进行服务相似性分区<sup>[15]</sup>, 将查询结果相同的位置集 (服务相似度为 1) 合并成一个区域, 即同一个分区内的任一位置的查询结果是相同的。因此相似地图定义如下。

**定义 8** 相似地图。给定一个服务区域  $S$ , 若  $S = S_i \cup S_j, S_i \cap S_j = \emptyset$ , 以及对其中任意的  $p_1, p_2 \in S_i$ ,  $\text{sim}(p_1, p_2) = 1$ , 则称  $S$  为相似地图。显而易见, 在同一相似区域  $S_i$  的任意位置的查询结果是相同的。

选取某一地区的 870 km<sup>2</sup> 区域内分布的麦当劳餐厅位置, 并将该区域划分为一个 300×290 的网格, 每网格的面积为 100 m×100 m, 并取 top-3 结果集, 生成相似区域 (用同一灰度值进行标识), 如图 1 所示。

**定义 9** 位置正确率。查询机制  $M$  的位置正确率为

$$\gamma = \frac{S[R(p) \cap R(M(p))]}{S[R(p)]} \quad (8)$$

其中,  $R(p)$  表示在真实位置  $p$  处查询的兴趣点的结果集,  $M(p)$  表示真实位置  $p$  在查询机制  $M$  下输出的假位置查询点,  $S[\cdot]$  表示集合数量。




图 1 相似区域

## 4 系统方案

根据观察发现, 预测位置往往随机分布在真实位置的周边, 攻击者无法根据预测位置推测出用户的真实位置, 因此可以将预测机制视为一种随机扰动。由于预测机制的隐私开销非常小, 甚至趋近于 0, 因此利用预测机制替代差分扰动能够有效降低连续查询的隐私开销。其次, 隐私具有差异化, 为不同的语义位置分配不同的隐私预算, 能够有效提高隐私预算利用率。例如, 可以为医院/家庭等敏感位置分配较小的预算, 而公园/商场等公共区域分配较大预算, 从而实现隐私预算的合理分配, 节省隐私开销。再者, 由于查询位置具有时空关联性, 单个位置满足  $\varepsilon$ -差分隐私, 并不能确保轨迹隐私安全。因此基于上述观察, 本文提出一种基于预测和滑动窗口的轨迹差分隐私保护机制, 主要包含以下策略。

### 1) 隐私预算量身定制

该机制允许用户自定义位置敏感度, 并依此量身定制隐私预算, 进一步提高轨迹隐私预算的利用率。

### 2) 预测扰动

利用马尔可夫链和指数扰动机制获得满足高可用性、差分安全和时空相关性约束的预测位置, 并引入服务相似地图校验预测位置的可用性。该策略利用预测的假位置替代差分扰动, 从而有效降低预算开销, 并进一步提高服务质量。

### 3) 基于 $w$ 滑动窗口的隐私预算分配机制

采用  $w$  滑动窗口机制分配连续查询中各位置点

的隐私预算，确保轨迹中的任意  $w$  个时间戳（位置点）的隐私消耗累计不超过  $\varepsilon$ ，即确保轨迹满足  $\varepsilon$ -差分隐私。

具体查询过程如算法 1 所示。

**算法 1** 基于预测和滑动窗口的轨迹差分隐私保护机制

输入  $Q^{(t-1)}, L^{(t-1)}, p, \text{map}_{\text{sen}}, U, \theta, w, \alpha, \delta, \text{map}_{\text{sim}}, \varepsilon, C, E, N$

输出  $z$

- ①  $p.\text{pl} \leftarrow \text{lookup}(\text{map}_{\text{sen}}, p)$
- ② if  $p.\text{pl} \leq \theta$
- ③  $z \leftarrow p$ ;
- ④ else {
- ⑤  $\varepsilon_e \leftarrow E \frac{\varepsilon}{w}$ ;
- ⑥  $\varepsilon_q \leftarrow C \frac{\varepsilon}{w}$   $\varepsilon_\theta \leftarrow C \frac{\varepsilon}{w}$ ;
- ⑦  $l \leftarrow \text{prediction}(U, \varepsilon_e, \delta, Q^{(t-1)}, L^{(t-1)})$ ;
- ⑧ if  $\text{test}(l, \alpha, \text{map}_{\text{sim}}, p, \varepsilon_\theta) = 0$
- ⑨  $z \leftarrow l$ ;
- ⑩ else
- ⑪ {  $\varepsilon_N \leftarrow \frac{N\varepsilon q\theta}{wp.\text{pl}}$ ;
- ⑫  $z \leftarrow N(\varepsilon_N, p)$ ;
- ⑬ }
- ⑭ end if
- ⑮ }
- ⑯ end if

算法 1 中， $\theta$  为用户设置的敏感度阈值； $p$  为用户的真实位置； $p.\text{pl}$  为真实位置的敏感度； $\text{lookup}$  为查询函数，即通过查找敏感度地图  $\text{map}_{\text{sen}}$ ，获取  $p.\text{pl}$ ； $L^{(t-1)}$  为用户在前一时刻的可能位置集； $Q^{(t-1)}$  为用户在前一时刻的可能位置概率； $w$  为滑动窗口； $\delta$  为  $\delta$ -位置集的参数； $\alpha$  为用户设置的服务相似度阈值； $\text{map}_{\text{sim}}$  为相似地图； $\varepsilon$  为用户设置的轨迹隐私预算之和； $C$ 、 $E$  和  $N$  分别为隐私预算分配机制中用户设置的参数； $U$  为状态转移概率矩阵； $\text{prediction}(U, \varepsilon_e, \delta, Q^{(t-1)}, L^{(t-1)})$  为基于马尔可夫链和指数扰动机制的预测机制，详见算法 2； $\text{test}(l, \alpha, \text{map}_{\text{sim}}, p, \varepsilon_\theta)$  为基于服务相似度的检测函数，详见算法 3； $N(\varepsilon_N, p)$  为当隐私预算为  $\varepsilon_N$  时，位置  $p$  在地理不可区分性的扰动机制中输出噪声位置，即  $z$ 。在算法 1 中，首先根据用户的真实位置获取位置的敏感度。如果

位置的敏感度小于用户设置的阈值  $\theta$ ，则检测成功，直接利用用户的真实位置获取服务（算法 1 的①~③）；否则通过隐私预算分配机制，分别获取预测机制和检测函数的隐私预算  $\varepsilon_e$  和  $\varepsilon_\theta$ （算法 1 的⑤~⑥）。算法 1 的⑦~⑨是利用该预测机制获取预测位置点  $l$ ，并检测预测位置的可用性。如果检测成功，直接采用预测的位置作为查询点；否则，通过隐私预算分配机制，获取地理不可区分性的隐私预算  $\varepsilon_N$ ，并进行随机扰动，即  $N(\varepsilon_N, p)$ ，将噪声位置作为当前的查询位置（算法 1 的⑩~⑫）。

#### 4.1 敏感度处理

文献[13]认为只有与敏感位置直接相连的语义位置才具有敏感度。然而，从随机扰动的分布角度看，那些靠近敏感位置的语义位置，即使与敏感位置不直接相连，仍然存在暴露敏感位置的风险，因此也应分配一定的敏感度。因此，本文考虑了位置点间的整体连通性，根据距离和出入度将敏感位置的隐私级别分别辐射给附近节点。首先，获取敏感位置附近具有隐私级别的位置节点集，即连接集  $\text{neighborSet}$ 。然后，将地图转化为无向图，根据距离和出入度，则任意位置  $g$  与敏感位置  $a$  的等价距离为  $g.\text{eDis} = \text{ED}(c-1)$ ，其中， $\text{ED}$  为  $g$  与  $a$  的欧氏距离， $c$  为两位置节点间最短路径所经过的节点数-1。进一步地， $\text{neighborSet} = \{g | g.\text{eDis} < b\}$ ，其中  $b$  为用户设置的阈值。最后，为敏感位置  $a$  的连接集  $\text{neighborSet}$  中的任意位置  $g$  分配隐私敏感度，如式(9)所示。

$$g.\text{pl} = \frac{\left[ \frac{1}{g.\text{eDis}} \right] \cdot a.\text{pl}}{\sum_{g' \in \text{neighborSet}} \frac{1}{g'.\text{eDis}}} \quad (9)$$

其中， $g.\text{pl}$  表示节点  $g$  分配的隐私敏感度。

为了计算方便，本文将地图网格化。然后，利用上述过程计算地图中各区域的敏感度，生成敏感度地图  $\text{map}_{\text{sen}}$ 。 $\text{map}_{\text{sen}}$  存储于手机端，用户可以在离线阶段获取位置的敏感度。

#### 4.2 预测机制

预测机制主要由基于马尔可夫链和指数扰动机制的预测机制和基于服务相似性的检测机制两部分构成。

针对预测机制的部分，本文利用马尔可夫链刻画用户真实位置间的时序相关性，其中，状态转移

概率矩阵  $U$  表示真实位置在区域间的转移可能性, 如状态转移概率矩阵  $U$  中元素  $u_{ij}$  表示用户从第  $i$  个区域移动到第  $j$  个区域的概率。这里假设状态转移概率矩阵  $U$  可事先在历史记录上计算得到。假设用户在  $t-1$  时刻产生的可能位置集为  $L^{(t-1)} = \{l_1^{(t-1)}, l_2^{(t-1)}, \dots, l_m^{(t-1)}\}$ , 其概率值为  $Q^{(t-1)} = \{q_1^{(t-1)}, \dots, q_m^{(t-1)}\}$ , 通过状态转移概率矩阵计算出  $t$  时刻的可能位置为  $L^{(t)} = \{l_1^{(t)}, l_2^{(t)}, \dots, l_n^{(t)}\}$ , 其概率值为  $Q^{(t)} = \{q_1^{(t)}, \dots, q_n^{(t)}\}$ , 其中  $Q^{(t)} = Q^{(t-1)}U$ 。由于通过转移矩阵计算  $t$  时刻位置集中的一些元素的概率较低, 因此本文用  $\delta$ -位置集 (见定义 6) 过滤概率较低的元素, 得到候选集  $\Delta X_t$ 。然而对于选择  $\Delta X_t$  中的元素作为预测位置点, 需要选择概率较高的元素。为了隐私性, 本文选取指数机制对其选择, 即  $E(\varepsilon_e): \Delta X_t \rightarrow l$ , 其中,  $\varepsilon_e$  为指数选择机制的隐私预算; 打分函数为  $f = f^{(t)} = \{f_1^{(t)}, \dots, f_m^{(t)}\}$ ,  $m$  为  $\delta$ -位置集中的元素个数。具体算法如算法 2 所示。该机制对输出结果添加了噪音, 但是概率高的元素仍以较大的概率输出, 从而使输出结果更加隐私并更合理。

**算法 2 预测机制**

输入  $L^{(t-1)}, Q^{(t-1)}, U, \delta, \text{map}_{\text{sim}}, p, \varepsilon, E, w$

输出  $l$

①  $Q^t = Q^{(t-1)}U$

② 基于  $L^{(t-1)}, Q^{(t-1)}$  和  $\delta$ , 利用式(6)计算  $\delta$ -位置集  $\Delta X_t$

③  $\varepsilon_e \leftarrow E \frac{\varepsilon}{w}$

④  $l \leftarrow E(\varepsilon_e, \Delta X_t)$

通过隐私预算分配机制, 本文分别获取指数机制的隐私预算  $\varepsilon_e$  (算法 2 的③)。  $E(\varepsilon_e, \Delta X_t)$  为隐私预算为  $\varepsilon_e$  时, 通过指数扰动机制在  $\Delta X_t$  中输出预测位置  $l$ 。在算法 2 中, 本文首先利用马尔可夫链计算当前时刻的可能位置集, 再利用  $\delta$ -位置集  $\Delta X_t$  过滤其中概率较低的位置点, 最后采用指数机制选出当前预测位置。

针对检测的部分, 为了评估预测位置的服务质量, 本文提出一种基于服务相似性的检测函数。其中基于服务相似性的检测函数  $\theta(\varepsilon_\theta, \alpha, l)$  为

$$\theta(\varepsilon_\theta, \alpha, l): X \rightarrow P(B)$$

$$\theta(\varepsilon_\theta, \alpha, l)(x) = \begin{cases} 0, & \text{sim}(p, l) \geq \alpha + \text{Lap}(\varepsilon_\theta) \\ 1, & \text{其他} \end{cases} \quad (10)$$

其中,  $l$  是预测位置;  $\text{sim}(p, l)$  是位置  $p$  与  $l$  的服务

相似度;  $B = \{0, 1\}$  是布尔函数, 输出“0”表示预测成功, “1”表示预测失败;  $\text{Lap}(\varepsilon_\theta)$  表示隐私预算为  $\varepsilon_\theta$  时 Laplace 扰动值。由于检测函数必然会泄露用户部分的位置隐私, 为了保证安全, 本文在检测函数中也引入 Laplace 的扰动机制。虽然检测函数用掉一部分隐私预算, 但是其相对满足  $\varepsilon$ -地理不可区分性的扰动隐私预算值较小, 因此节省了隐私预算, 同时提高了服务质量。服务器预先生成相似地图  $\text{map}_{\text{sim}}$ , 供客户端下载, 从而在离线阶段通过相似地图检测 2 个位置的服务相似度。对于该检测机制, 其具体过程如算法 3 所示。

**算法 3 检测机制**

输入  $\alpha, l, \text{map}_{\text{sim}}, p, C, \varepsilon, w$

输出  $O$

①  $\varepsilon_\theta \leftarrow C \frac{\varepsilon}{w}$

② if  $\text{sim}(\text{map}_{\text{sim}}, p, l) \geq \alpha + \text{Lap}(\varepsilon_\theta)$

③  $O = 0$

④ else

$O = 1$

⑤ end if

算法 3 中,  $l$  为预测的位置。算法 3 利用算法 2 预测输出的预测位置  $l$ , 与真实位置进行服务相似度的检测。如果满足可用性需求记为 0, 否则记为 1, 并相应输出。

**4.3  $w$  序列满足  $\varepsilon$ -差分隐私的隐私预算分配机制**

从查询机制可知, 每个位置在指数扰动阶段、检测函数检测阶段和地理不可区分性的扰动阶段分别需要分配的隐私预算为  $\varepsilon_e, \varepsilon_\theta$  和  $\varepsilon_N$ 。如果一个时间戳的假位置预测成功, 利用预测位置作为查询位置。生成查询位置的过程共经历了指数扰动机制和检测函数 2 个阶段, 因此花费的隐私预算为  $\varepsilon_e + \varepsilon_\theta$ 。如果检测失败, 则利用地理不可区分性的扰动产生查询点, 其经历了 3 个阶段, 因此花费的隐私预算为  $\varepsilon_e, \varepsilon_\theta$  和  $\varepsilon_N$  之和, 则有

$$\varepsilon_i = \begin{cases} \varepsilon_e + \varepsilon_\theta, & P(B) = 0 \\ \varepsilon_e + \varepsilon_\theta + \varepsilon_N, & P(B) = 1 \end{cases} \quad (11)$$

其中,  $\varepsilon_i$  为连续的 LBS 查询中, 第  $i$  个查询位置分配的总隐私预算。若  $P(B) = 0$ , 预测成功, 反之预测失败。从式(11)也可以看出, 如果预测失败, 反而花费更多的隐私预算, 因此要提高预测成功率, 节省隐私预算。

从差分隐私的序列组合特性可以看出, 在连续

的 LBS 查询中,无法保证轨迹的隐私。因此本文考虑将轨迹片段化,引入  $w$  滑动窗口机制,使其轨迹满足  $w$  连续序列  $\varepsilon$ -差分隐私。首先,  $w$  滑动窗口是指用户连续查询的时间戳长度为  $w$  的位置序列,其形式如图 2 所示。轨迹中任意一个时间戳为一个窗口,每个窗口对应的隐私预算为  $\varepsilon_i$ 。其次,设计隐私预算分配机制为  $\varepsilon_e$ 、 $\varepsilon_\theta$  和  $\varepsilon_N$  分配相应的隐私预算。




图2  $w$  滑动窗口示意

为了使轨迹满足  $\varepsilon$ -差分隐私,引入参数  $E$ 、 $C$  和  $N$  调节隐私预算,且  $E+N+C=1$ ,具体预算分配机制如下。

对于指数扰动机制,每个位置分配到的隐私预算  $\varepsilon_e$  为

$$\varepsilon_e = \frac{E\varepsilon}{w} \quad (12)$$

指数机制中的打分函数为  $f=Q^{(i)}=\{q_1^{(i)}, \dots, q_m^{(i)}\}$ ,由于序列组合特性,因此  $\delta$ -位置集中的每个位置分配的隐私预算为  $\frac{\varepsilon_e}{m}$ 。

对于检测函数检测阶段,每个位置分配到的隐私预算  $\varepsilon_\theta$  为

$$\varepsilon_\theta = \frac{C\varepsilon}{w} \quad (13)$$

由于隐私具有主观性,在每一点上进行同等扰动并不合理。不仅用户对不同语义位置的敏感度不同,而且不同用户对同一个语义的敏感性也是存在差异。因此,本文引入敏感度量身定制策略,提高隐私预算的利用率。对于敏感度越高的位置,分配较小的隐私预算,即加入越大的扰动噪音,从而获得更高的隐私保护程度。首先,对于初始值  $(r, \theta)$  分配相应的隐私预算  $\varepsilon = \frac{N\varepsilon}{w}$ 。其中  $(r, \theta)$  指半径为  $r$ , 敏感度为  $\theta$ 。其次,考虑位置敏感度,敏感度越高,对于噪音扰动阶段分配的隐私预算越低,保护半径越小。因此,对于任意敏感度  $g.pl$ ,其半径的选择为  $r = \frac{r\theta}{g.pl}$ ,从而对于满足地理不可区分性的

扰动,每个位置分配到的隐私预算  $\varepsilon_N$  为

$$\varepsilon_N = \frac{N\varepsilon\theta}{w(g.pl)} \quad (14)$$

其中,  $E+C \leq N$  且  $g.pl \in [\theta, 1]$ 。为了节省隐私预算,在预测阶段的预算值要小于扰动阶段的预算值,因此  $E+C \leq N$ 。

## 5 隐私分析

本节证明本文查询机制的发布轨迹能够满足  $w$  连续序列  $\varepsilon$ -差分隐私。

根据定义 5,本文首先可以证明  $E(\varepsilon_e)$ 、 $\theta(\varepsilon_\theta, \alpha, l)$  和  $N(\varepsilon_N)$  分别满足  $\varepsilon_e$ -差分隐私、 $\varepsilon_\theta$ -差分隐私和  $\varepsilon_N$ -差分隐私。从而,可以进一步证明本文查询机制  $M_i$  满足  $\varepsilon_i$ -差分隐私,其中  $\varepsilon_i = \varepsilon_e + \varepsilon_\theta + \varepsilon_N$ 。证明过程见附录。

基于上述分析,本文可以证明轨迹满足  $w$  连续序列  $\varepsilon$ -差分隐私,即本文机制的轨迹中任意连续  $w$  个位置的隐私预算之和为  $\varepsilon$ 。形式化表达如定理 1 所示。

**定理 1** 任意一个  $w$  个时间戳的连续发布位置序列子集  $\{z_{i-w+1}, \dots, z_i\}$ , 轨迹隐私保护满足  $w$  连续序列  $\varepsilon$ -差分隐私。即

$$\forall i \in [t], \sum_{k=i-w+1}^i \varepsilon_k \leq \varepsilon \quad (15)$$

**证明** 首先  $E(\varepsilon_e)$ 、 $\theta(\varepsilon_\theta, \alpha, l)$  和  $N(\varepsilon_N)$  分别满足  $\varepsilon_e$ -差分隐私,  $\varepsilon_\theta$ -差分隐私和  $\varepsilon_N$ -差分隐私,由于本文机制由这 3 种机制组合而成,因此查询机制  $M_i$  满足  $\varepsilon_i$ -差分隐私,其中  $\varepsilon_i = \varepsilon_e + \varepsilon_\theta + \varepsilon_N$ 。因此对于任意  $w$  个时间戳的隐私预算之和为

$$\begin{aligned} \sum_{k=i-w+1}^i \varepsilon_k &\leq \sum_{k=i-w+1}^i \frac{C\varepsilon}{w} + \sum_{k=i-w+1}^i \frac{M\varepsilon}{w} + \sum_{k=i-w+1}^i \frac{N\varepsilon\theta}{w(g.pl)} \leq \\ &\sum_{k=i-w+1}^i \frac{E\varepsilon}{w} + \sum_{k=i-w+1}^i \frac{C\varepsilon}{w} + \sum_{k=i-w+1}^i \frac{N\varepsilon}{w} = \sum_{k=i-w+1}^i \frac{(E+C+N)\varepsilon}{w} = \varepsilon \end{aligned} \quad (16)$$

证毕。

## 6 实验分析与评估

本文分析了模型参数在 2 种真实数据集中对于可用性的影响。同时,将本文方案与 DPLRM<sup>[13]</sup> 机制和 PM<sup>[14]</sup> 机制进行对比分析,从而验证本文方案的有效性。

### 6.1 实验数据集与设置

实验采用 Geolife<sup>[16]</sup> 和 Gowalla<sup>[17]</sup> 这 2 个数据集,其

中, Geolife 采集了 182 个用户 2007 年 4 月至 2012 年 8 月在北京活动的真实数据, 共包含 17 621 条轨迹。数据集包含用户编号、时间戳、经度、纬度、海拔等信息。本文从该数据集中抽取 50 条北京某一地区的轨迹进行采样, 采样方法如下。每隔 1 min 采取一个样本点作为用户的查询点, 如果 2 个连续位置的间隔大于 1 min, 则该位置被随机取样。50 条轨迹采样后大约有 500 个位置。为方便计算, 本文将地图划分为 300 m×300 m 的网格, 并将用户真实位置规格化到网格中心。Gowalla 采集了 15 116 个用户 2009 年 2 月至 2010 年 10 月在移动社交网站上(美国加州范围内)的签到数据。同 Geolife 一样, 本文抽取加州范围内的用户编号、时间戳、经度、纬度作为新的数据集, 并将其地图划分为 0.89 m×0.89 m 的网格。

### 6.2 可用性评估

本文发现预测成功率会直接影响 LBS 的可用性与隐私风险, 因此提高预测成功率对基于预测机制的隐私保护方案至关重要。可用性阈值  $\alpha$  与预测成功率的函数关系如图 3 所示, 并引入 PM 方案进行对比。从图 3 可看出, 两者的成功率都随着  $\alpha$  的升高而逐渐下降, 但本文的预测成功率始终明显高于 PM 方案。这是由于在基于服务相似性的检测函数中,  $\alpha$  越大, 满足可用性要求的位置越少, 因此预测成功率必然下降。此外, 本文方案采用了马尔可夫链的预测机制, 能够有效提高预测成功率。

本文利用定义 9 的轨迹中位置正确率的平均值和真实位置与其发布位置之间的均方根误差 (RMSE, root mean square error) 这 2 种测量矩阵去测量的轨迹的可用性。其中, 用户真实轨迹位置和查询位置轨迹分别为  $P=\{p_1, p_2, \dots, p_n\}$  和  $Z=\{z_1, z_2, \dots, z_n\}$ , 则

$$RMSE = \frac{1}{n} \sum_{i=1}^n d_2(p_i, z_i) \quad (15)$$

首先, 本文分别分析敏感度阈值  $\theta$  在 Geolife 和 Gowalla 数据集中对 RMSE 和位置正确率的影响, 结果如图 4 和图 5 所示。在该实验中,  $w=3$ ,  $\alpha=0.5$ ,  $\varepsilon=1.8$ ,  $b=500$ ,  $N=\frac{1}{3}$ ,  $E=\frac{1}{3}$  和  $C=\frac{1}{3}$ 。从图 4 中可以看出, 本文方案的可用性随着  $\theta$  的升高而提高。 $\theta$  越高, 一方面, 在扰动阶段每个位置分配到的隐私预算提高, 可用性也提高; 另一方面, 更多

位置的敏感度小于  $\theta$ , 从而不需要扰动, 因此可用性更好。但是当  $\theta$  取值为 0.16 时, RMSE 为 0。这是因为在本文的敏感度划分方法中, 当  $b$  设置为 500 时, 地图内区域的敏感最高为 0.15。因此当  $\theta$  取值为 0.16 时, 地图中所有位置都是不敏感位置, 直接发布, 因此轨迹的平均 RMSE 为 0。此外, Geolife 数据集中的可用性好于 Gowalla 数据集, 因为 Gowalla 数据集划分区域的网格较大, 2 个位置间的距离较远, 所以可用性较差。最后, 本文的可用性高于 PM 方案和 DPLRM 方案。首先, 本文的预测成功率高于 PM 方案。其次, 因为 PM 方案不考虑隐私的个性化设置, 隐私预算的利用率低, 扰动不确定性高, 可用性差。DPLRM 方案虽然考虑隐私与可用性的平衡, 但是在隐私中既考虑发布位置对当前位置影响, 又考虑了对之前位置影响, 限制因素较多, 并且本文方案中引入了可用性检测, 故可用性高。





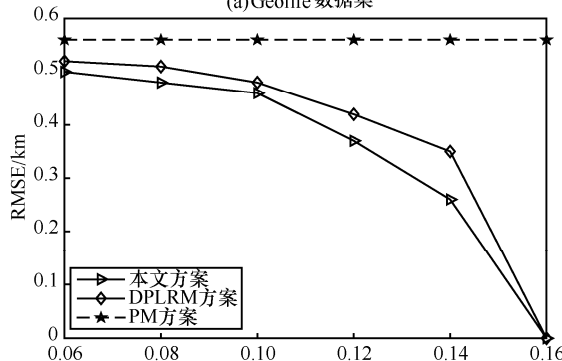
图 3 可用性阈值  $\alpha$  与预测成功率的函数关系

从图 5 中可以看出, 位置正确率随着  $\theta$  的增大而提高。因为从图 4 中得到,  $\theta$  越大, RMSE 越小, 因此位置正确率越高。当 RMSE=0 时, 正确率最高, 接近于 1。此外, Geolife 数据集中的可用性也高于 Gowalla 数据集, 同时本文的位置正确率也高于 DPLRM 方案和 PM 方案。

本文还应该探究在给定轨迹隐私预算, 滑动窗口长度与可用性的关系和给定滑动窗口轨迹的隐私预算与可用性的关系。但是二者之间的本质问题是相同的, 都是探求隐私预算与可用性的关系, 因此, 本文分析滑动窗口长度对可用性的影响, 结果如图 6 和图 7 所示。在这一系列实验中, 本文假设  $\varepsilon=1.8$ ,  $b=500$ ,  $\theta=0.01$ ,  $\alpha=0.5$ 。从图 6 中可以看出, RMSE 随着滑动窗口  $w$  的数量增大而提高。 $w$  越大, 每个位置分配的隐私预算越少, 则预测成功




(a) Geolife 数据集




(b) Gowalla 数据集

图 4 敏感性阈值  $\theta$  对 RMSE 的影响



(a) Geolife 数据集




(b) Gowalla 数据集


图 5 敏感性阈值  $\theta$  对位置正确率的影响

率越低，并且满足地理不可区分性的扰动越大，从而降低了隐私可用性。Geolife 数据集中的可用性高

于 Gowalla 数据集，与图 4 的原因相同。本文的可用性高于 DPLRM 方案和 PM 方案。DPLRM 方案对于发布位置的约束条件较多，从而导致较远的位置满足约束条件，并且本文方案中引入了可用性检测，可用性高。PM 方案利用前一次的查询点作为检测位置点，然而本文中进一步改进利用基于服务相似性检测以及马尔可夫模型的预测机制，预测成功率更高，因此可用性最好。



(a) Geolife 数据集



(b) Gowalla 数据集

图 6  $w$  滑动窗口对 RMSE 的影响

从图 7 中可以看出，位置正确率随着滑动窗口  $w$  数量的上升而降低，同时 Geolife 数据集中的可用性也高于 Gowalla 数据集，此外，本文方案的位置正确率也高于 DPLRM 方案和 PM 方案。

### 6.3 系统运行时间评估

本节评估了本文算法的时间开销，并与 DPLRM 方案比较，如图 8 所示。为了方便比较，本文的实验设置与 DPLRM 算法相同，选取数据集为 Geolife 数据集，将北京地图划分为大小为  $0.34 \text{ km} \times 0.34 \text{ km}$  的网格，初始敏感位置个数设为 10，并且敏感度计算方法也与 DPLRM 相同。从图 8 可以看出，本文方案的运行时间远远小于 DPLRM 方案。DPLRM 方案中最耗时的部分在于计算其后




图7 w 滑动窗口对位置正确率的影响




图8 θ 对方案运行时间 t 的影响

验概率，其复杂度为  $O(wN^3)$ ，其中  $N$  为用户  $t$  时刻可能的真实位置区域个数和满足限制条件的发布区域个数。可能的真实位置区域个数也是由马尔可夫链计算的，如果查询时间较长，则可能的真实位置区域个数非常大，在实际应用中需要多个服务器并行计算。而在本文方案中，指数选择与地理不可区分性的计算时间与可能区域的个数呈线性增长。此外，利用转移矩阵计算可能位置的概率，这部分计算 DPLRM 算法也已经包括，并且开销也很低。

## 7 结束语

为解决轨迹差分隐私保护中存在的隐私预算

与服务质量等问题，本文提出一种基于预测和滑动窗口的轨迹差分隐私保护机制。首先，允许用户自定义位置敏感度，并依据敏感度量身定制隐私预算，提高预算的利用率。其次，利用马尔可夫链和指数扰动机制获得满足高可用性、差分安全和时空相关性约束等 3 个目标的预测位置，并引入服务相似地图校验预测位置的可用性。该策略可以有效降低预算开销，并进一步提高服务质量。最后，采用滑动窗口  $w$  机制分配连续查询中各位置点的隐私预算，确保轨迹中的任意  $w$  个时间戳（位置点）的隐私消耗累计不超过  $\epsilon$ ，从而实现连续查询的轨迹满足  $\epsilon$ -差分隐私。今后将考虑研究如何对本文算法进行继续优化，以提高查询的可用性。

## 附录 查询机制 $M_i$ 满足 $\epsilon_i$ -差分隐私证明

对于指数扰动机制、检测函数检测与噪音扰动机制分别满足  $\epsilon$ -差分隐私，即

$$\forall \epsilon_\beta \quad E(\epsilon_e) \quad \text{满足 } \epsilon_e\text{-差分隐私}$$

$$\forall \epsilon_\theta, \alpha, l \quad \theta(\epsilon_\theta, \alpha, l) \quad \text{满足 } \epsilon_\theta\text{-差分隐私}$$

$$\forall \epsilon_N \quad N(\epsilon_N) \quad \text{满足 } \epsilon_N\text{-差分隐私}$$

则查询机制  $M_i$  满足  $\epsilon_i$ -差分隐私，其中  $\epsilon_i = \epsilon_\beta + \epsilon_\theta + \epsilon_N$ 。

### 证明

在预测阶段选取的机制为指数机制，因此  $E(\epsilon_e)$  满足  $\epsilon_e$ -差分隐私，其中  $d_x(p, p')=1$ 。

在检测函数检测阶段，有

$$P[\text{sim}(p, l) \geq \alpha + \text{Lap}(0)] = P[\text{Lap}(\text{sim}(p, l) - \alpha) \geq 0] =$$

$$P[\text{Lap}(t) \geq 0] \leq e^{\epsilon_\theta d(t, t')} P[\text{Lap}(t') \geq 0] \leq$$

$$e^{\epsilon_\theta} P[\text{Lap}(t') \geq 0] = e^{\epsilon_\theta} P[\text{sim}(p', l) \geq \alpha + \text{Lap}(0)]$$

$$d(t, t') = |\text{sim}(p, l) - \alpha - \text{sim}(p', l) + \alpha| \leq 1$$

因此， $\forall \epsilon_\theta, \alpha, l$ ，检测函数检测  $\theta(\epsilon_\theta, \alpha, l)$  满足  $\epsilon_\theta$ -差分隐私，其中  $d_x(p, p')=1$ 。

在位置扰动阶段选取的机制为基于地理不可区分性的扰动，因此  $N(\epsilon_N)$  满足  $\epsilon_N$ -差分隐私。

根据序列组合特性， $\epsilon_i = \epsilon_e + \epsilon_\theta + \epsilon_N$ 。因此，查询机制  $M_i$  满足  $\epsilon_i$ -差分隐私。

证毕。

## 参考文献:

- [1] MADDEN M, LENHART A, CORTESI S, et al. Pew internet and american life project[J]. Washington, DC: Pew Research Center, 2010.
- [2] DOBSON J E, FISHER P. Geoslavery[J]. Technology and Society Magazine, 2003, 22(1):47-52.
- [3] ANDRÉS M E, BORDENABE N E, CHATZIKOKOLAKIS K.

- Geo-indistinguishability: differential privacy for location-based systems[C]//Proceedings of the 2013 ACM SIGSAC Conference on Computer & Communications Security. New York: ACM Press, 2013: 901-914.
- [4] DWORK C, MCSHERRY F, NISSIM K. Calibrating noise to sensitivity in private data analysis[C]//Theory of Cryptography Conference. Berlin: Springer, 2006: 265-284.
- [5] GRUTESER M, GRUNWALD D. Anonymous usage of location-based services through spatial and temporal cloaking[C]// Proceedings of the 1st International Conference on Mobile Systems, Applications And Services. New York: ACM Press, 2003: 31-42.
- [6] NIU B, LI Q, ZHU X, et al. Achieving  $k$ -anonymity in privacy-aware location-based services[C]//The 33rd Annual IEEE International Conference on Computer Communications. Piscataway: IEEE Press, 2014: 754-762.
- [7] HWANG R H, HSUEH Y L, CHUNG H W. A novel time-obfuscated algorithm for trajectory privacy protection[J]. IEEE Transactions on Services Computing, 2013, 7(2): 126-139.
- [8] WANG J, LI Y, YANG D, et al. Achieving effective  $k$ -anonymity for query privacy in location-based services[J]. IEEE Access, 2017(5): 24580-24592.
- [9] KIDO H, YANAGISAWA Y, SATOH T. Protection of location privacy using dummies for location-based services[C]// 21st International Conference on Data Engineering Workshops. Piscataway: IEEE Press, 2005: 1248-1248.
- [10] ANDRÉS M E, BORDENABE N E, CHATZIKOKOLAKIS K. Geo-indistinguishability: differential privacy for location-based systems[C]//Proceedings of the 2013 ACM SIGSAC conference on Computer & communications security. New York: ACM Press, 2013: 901-914.
- [11] XIAO Y, XIONG L. Protecting locations with differential privacy under temporal correlations[C]//ACM Sigsac Conference on Computer and Communications Security. New York: ACM Press, 2015: 1298-1309.
- [12] HUA J, TONG W, XU F. A geo-indistinguishable location perturbation mechanism for location-based services supporting frequent queries[J]. IEEE Transactions on Information Forensics and Security, 2017, 13(5): 1155-1168.
- [13] 吴云乘, 陈红, 赵素云. 一种基于时空相关性的差分隐私轨迹保护机制[J]. 计算机学报, 2018, 41(2): 309-322.
- WU Y C, CHEN H, ZHAO S Y. Differentially privacy trajectory protection based on spatial and temporal correlation[J]. Chinese Journal of Computers, 2018, 41(2): 309-322.
- [14] CHATZIKOKOLAKIS K, PALAMIDESSI C, STRONATI M. A predictive differentially-private mechanism for mobility traces[M]//Privacy Enhancing Technologies. Berlin: Springer International Publishing, 2014.
- [15] 叶阿勇, 李亚成, 马建峰, 等. 基于服务相似性的  $k$ -匿名位置隐私保护方法[J]. 通信学报, 2014, 35(11):162-169.
- YE A Y, LI Y C, MA J F, et al. Location privacy-preserving method of  $k$ -anonymous based on service similarity[J]. Journal on Communications, 2014, 35(11): 162-169.
- [16] ZHENG Y, XIE X, MA W Y. GeoLife: a collaborative social networking service among user, location and trajectory[J]. IEEE Data Engineering Bulletin, 2010, 33(2): 32-39.
- [17] CHO E, MYERS S A, LESKOVEC J. Friendship and mobility: user movement in location-based social networks[C]//Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining. New York: ACM Press, 2011: 1082-1090.

#### [作者简介]



叶阿勇（1977- ），男，福建福州人，博士，福建师范大学教授，主要研究方向为无线网络技术、隐私与安全、信息服务等。

孟玲玉（1994- ），女，黑龙江安达人，福建师范大学硕士生，主要研究方向为网络空间安全、位置隐私保护等。

赵子文（1992- ），男，山东枣庄人，福建师范大学硕士生，主要研究方向为网络空间安全、位置隐私保护等。

刁一晴（1997- ），女，山东济南人，福建师范大学硕士生，主要研究方向为网络空间安全、区块链隐私保护等。

张娇美（1995- ），女，河南洛阳人，福建师范大学硕士生，主要研究方向为网络空间安全、机器学习隐私保护等。