

一种融合差分隐私的随机游走算法

华雯丽, 黄刚, 唐震

(南京邮电大学 计算机学院、软件学院、网络空间安全学院, 江苏 南京 210023)

摘要: 如今的信息化时代, 用户之间的社交网络信息越发详细, 发布这些网络数据经常会威胁到一些个人隐私。而推荐算法中, 根据用户物品之间的二分图关系, 进行随机游走推荐, 能更可靠地推荐目标用户可能选择的物品。由于随机游走复杂度过高, 一般将图转化成转移矩阵进行计算, 但是游走时无法保证该目标用户以及其他用户的隐私信息。在隐私得不到保护的前提下, 用户个人利益会受到威胁, 也容易导致丢失用户的后果。对此, 需要在发布图之前处理好数据, 尽量保证数据的隐私性。而差分隐私能够在数学定义上很好地保证用户的隐私, 由此在随机游走算法(PersonalRank)的基础上, 对转移矩阵通过拉普拉斯机制加噪, 随机游走计算之后, 再以指数机制输出推荐结果, 保证了用户的信息隐私。

关键词: 随机游走; 转移矩阵; 差分隐私; 拉普拉斯机制; 指数机制

中图分类号: TP309

文献标识码: A

文章编号: 1673-629X(2021)09-0112-06

doi: 10.3969/j.issn.1673-629X.2021.09.019

A PersonalRank Walk Algorithm Fusing Differential Privacy

HUA Wen-li, HUANG Gang, TANG Zhen

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: In today's information age, social network information between users is becoming more and more detailed, and the release of such network data often threatens some personal privacy. In the recommendation algorithm, random walking recommendation is carried out according to the relationship between users and items, which can more reliably recommend the items the target user may choose. Due to the high complexity of the random walk, the graph is generally transformed into the transition matrix for calculation, but the privacy information of the target user and other users cannot be guaranteed during the walking. Without the protection of privacy, users' personal interests will be threatened, which will easily lead to the loss of users. In this regard, it is necessary to deal with the data before publishing the graph, and try to ensure the privacy of the data. Differential privacy can guarantee users' privacy in mathematical definition. Therefore, on the basis of PersonalRank, the transfer matrix is denoised by Laplace mechanism. After the random walk calculation, the recommendation results are output by exponential mechanism, which ensures users' information privacy.

Key words: random walk; transfer matrix; differential privacy; Laplace mechanism; exponential mechanism

0 引言

近些年, 由于移动互联网的兴起, 数以亿计的人已经深度接入了互联网。2020年第1季度, 全球各大网络社交应用平台用户数量进一步膨胀: 推特3.7亿, 微信12亿, 抖音5.18亿, Facebook 20亿。庞大的社交网络数据, 一方面, 可以为人们提供越来越符合心意的推荐, Georg Groh和Christian Ehmig的研究^[1]表明, 在几个真实的推荐系统中, 基于社会化推荐系统的用户满意度, 明显高于基于协同过滤算法的系统, 其最关键的部分是基于好友的选择进行推荐。但是另一方面, 个人信息的选择暴露在网络中。用户的个人隐私得不到保障, 既会损失用户的利益, 也会因此反过来丢失注

意隐私的用户。对此, 需要设计一些机制, 尽量保证数据的隐私性。

针对保护隐私的方法, 一般有两种, 一种是对匿名方法^[2], 但是网络图的特殊性, 使得匿名数据遇到节点度数或者结构的攻击, 更容易被识别出来, 比如, 在并不想披露朋友之间的关系的情况下, 识别出该独特关系的图数据。另一种算法—差分隐私保护(differential privacy)^[3-6], 是由Dwork等提出的新型隐私保护模型, 从定义上保证隐私, 且与大量的背景知识无关, 这种隐私保护算法不仅仅从理论上可以保护隐私, 也被用在现实工业应用中^[7-10]。

文中的主要工作就是在保证推荐的同时, 进行差

收稿日期: 2020-10-18

修回日期: 2021-02-23

基金项目: 江苏省教育基金资助项目(17JS010); 中国电信公司江苏分公司基金资助项目(DGJ02)

作者简介: 华雯丽(1995-), 女, 硕士, 研究方向为推荐系统、差分隐私; 黄刚, 教授, 研究方向为数据挖掘。

分隐私操作,保护用户以及好友的个人隐私,主要分为以下几步:

(1)处理用户和物品的二分图,转化成转移矩阵作为数据的输入;

(2)对转移矩阵基于拉普拉斯机制加噪,再进行随机游走;

(3)随机游走得到推荐物品与推荐目标的关联分值列表;

(4)将每个推荐结果的分值,根据指数机制得到最终的推荐结果。

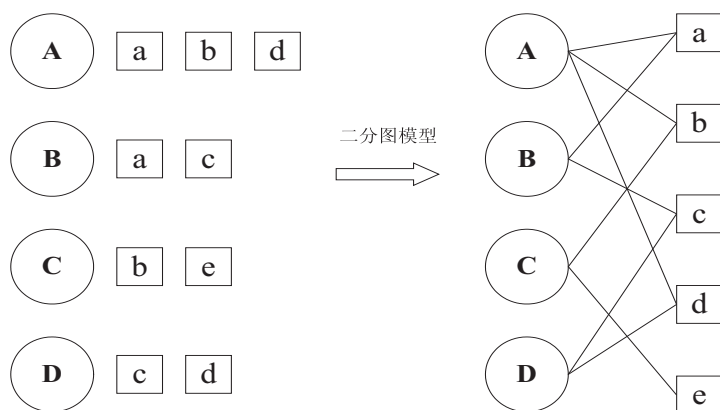


图1 用户与物品之间的二分图

1.2 二分图节点的重要性

得到用户与物品的二分图之后,需要对指定用户进行个性化的推荐,则主要是计算节点之间的相关性,在用户未选择的物品列表中,选择对指定用户节点重要性最高的那个节点,节点重要性越高,对于指定用户节点相关性就越高。

节点之间的重要性比较,第一个重要性是路径个数,指定用户节点到相关的物品节点之间的路径越多,该物品节点对于指定用户节点的重要性越高。举一个例子,如图2所示,假设目标用户是A,A已经连接a,b,d,需要比较c,e两个节点对A节点的重要性,图中左边的二分图中,加粗的线表示A到c有一条路径,

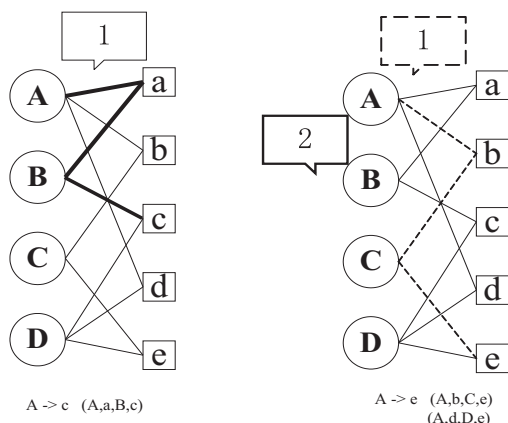


图2 A与a,e之间相关性比较

1 相关概念以及背景知识

1.1 用户行为数据的二分图表示

用户行为有很多种方法可以表示,本节主要讨论用二分图表示用户行为^[11]。

由二元组能够表示用户的行为,例如一个二元组 (u, i) 代表用户 u 和物品 i 有行为关系。这些二元组可以直接组成一个二分图。例如,将用户顶点和物品顶点构成一个用户物品二分图,其中顶点之间的边表示用户 u 对物品 i 产生的行为。如图1所示,左边表示用户和物品节点,用户A对a,b,d都产生行为,转化成二分图,将A和a,b,d连接起来。

长度为3,为 (A, a, B, c) ;图中右边的二分图中,有两组从A到e的路径,长度也为3,为 (A, b, C, e) 和 (A, d, D, e) ,相对于c来说,e的重要性更高。

另外一个重要性比较是从节点之间的路径来看,越分散,重要性越差。如图3所示,从A到e的两条路径, (A, b, C, e) 经过的顶点的出度为 $(3, 2, 2, 2)$,而另外一条 (A, d, D, e) 经过的顶点个数为 $(3, 2, 3, 2)$,两者比较, (A, d, D, e) 经过节点D的出度较大,重要性分散较多。所以,对于节点A到e的重要性而言,路径 (A, b, C, e) 比路径 (A, d, D, e) 的贡献要大。

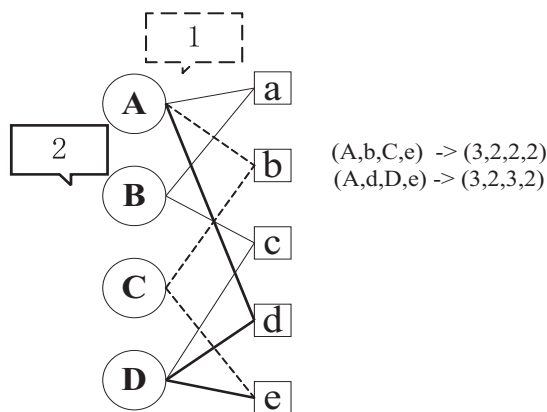


图3 A到e的路径比较

1.3 PageRank

随机游走算法^[12]的主要思想来自 Google 的

PageRank, 可以计算不同网页之间的重要性, 进行排名显示重要性高的节点, 该算法的公式如下:

$$PR(i) = \frac{1 - \partial}{N} + \partial \sum_{j \in \text{in}(i)} \frac{PR(j)}{|\text{out}(j)|}$$

其中, $PR(i)$ 是节点 i 被访问到的概率, ∂ 是用户继续访问节点的概率, N 是所有节点的数量, $\text{in}(i)$ 是所有指向节点 i 的节点集合, $\text{out}(j)$ 是节点 j 指向的其他节点集合。

在这个公式中, 节点 i 被点击到的概率由两部分组成: 第一部分, 节点 i 作为起点, 第一个被用户点击后停留在当前节点的概率为 $\frac{1 - \alpha}{N}$ 。第二部分, 用户点击其他节点后, 无论节点 i 是不是起点, 再次跳转回到节点 i 的概率: $\alpha \sum_{j \in \text{in}(i)} \frac{PR(j)}{|\text{out}(j)|}$, 这两部分的和便是节点 i 被点击到的概率。

1.4 差分隐私的介绍

差分隐私算法^[13-14]在于, 向查询输出结果中添加噪声, 从而隐藏敏感数据, 同时能够保证处理之后的数据, 不会影响数据挖掘的结果。假设一个攻击者, 有足够大的背景知识的支撑下, 就能够从 $N-1$ 条数据记录中查询做差得到被攻击者的隐私, 但是差分隐私能够从定义上解决这个问题。

其核心思想主要体现在两个方面, 其一, 在插入和删除任意一条数据记录时不会影响输出的结果; 其二, 无论是否有足够的背景知识, 隐私信息也不会泄露。其定义如下:

定义: 对于两个数据集 D 和 D' , D 和 D' 相差一条记录, 记作 $|D \Delta D'| \leq 1$, 现有一个随机算法 A , $\text{range}(A)$ 表示该算法的取值范围, 如果 A 在 D 和 D' 数据集上输出的结果 S , $S \in \text{range}(A)$, 符合下面的公式, 则称 A 满足 ϵ -差分隐私。

$$\Pr[A(D) \in S] \leq e^\epsilon \times \Pr[A(D') \in S]$$

其中, ϵ 是指隐私保护参数, 可以表示隐私保护的程, 该值越小, 表示保护的程, 越高, $\Pr[\]$ 是隐私被泄露的概率。

(1) 敏感度: 函数的敏感度可以分为全局敏感度和局部敏感度。这里主要说明全局敏感度, 全局敏感度是指对于该函数, 在两个 D 和 D' 数据集上输出的最

大差别, 其形式化定义如下:

对于一个任意函数 $f: D \rightarrow R^d$, d 表示函数 f 的维度, 则函数 f 的 L_k 全局敏感度 $S_k(f)$ 为:

$$S_k(f) = \max_{D, D'} \|f(D) - f(D')\|_k$$

其中: 数据集 D 和 D' 相差一条记录, $\|\cdot\|_k$ 表示 L_k 范数。

(2) 拉普拉斯机制。

Dwork 等人在文献[6]中提出差分隐私保护模型, 提出拉普拉斯机制, 可以取得差分隐私保护效果, 就是通过添加拉普拉斯随机噪声, 可以实现差分隐私保护。拉普拉斯分布的概率密度函数为:

$$f(x | \mu, b) = \frac{1}{2b} \exp(-|x - \mu|)$$

其中, μ 和 b 分别是针对变量 x 的期望和尺度参数。为了方便得到噪声, 设 $\mu = 0$, 则拉普拉斯分布可以看作是对称指数分布, 标准差为 $\sqrt{2}b$ 。在实现隐私保护时, 拉普拉斯随机噪声可以用以下公式计算:

$$\text{Laplace}\left(\frac{\Delta f}{\epsilon}\right)$$

其中, Δf 是针对函数 f 的全局敏感度, ϵ 是差分隐私保护参数。产生的噪声与 Δf 成正比, 与 ϵ 成反比。

(3) 指数机制。

指数机制的原理是定义一个打分函数 q , 用来评价每种输出可能性的分值, 分值高的输出可能性就会有更高的概率被发布, 主要是用于计数统计, 例如投票计算。指数机制可以用下面的定义表示。

针对随机算法 A , $q(D, r) \rightarrow R$, 数据集 D , 输出为一实体对象 $r \in \text{Range}$, $q(D, r) \rightarrow R$ 为可用性函数, 用来表示输出的可能性。若算法 A 以正比于 $e^{\epsilon \cdot q(D, r) / 2\Delta q}$ 的概率, 从 Range 中选择并输出 r , Δq 是函数的敏感度, 那么算法 M 提供 ϵ 差分隐私保护。

指数机制的敏感度: $S(q) = \max \|q(T_1, R) - q(T_2, r)\|$, 其中 r 是任意合法的输出。

差分隐私数据保护框架一般分为以下两种^[15]:

(1) 交互式保护: 用户请求查询数据库, 数据库将真实的结果进行差分隐私保护, 比如加上噪声, 然后将加上噪声的结果返回给用户, 如图 4 所示。

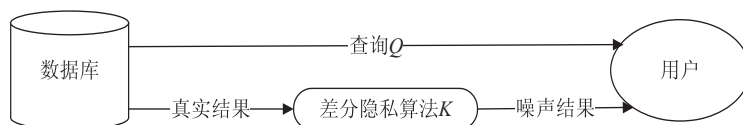


图 4 交互式框架

(2) 非交互式保护: 数据库直接用差分隐私进行保护, 形成隐私数据库, 直接与用户交互的数据库是隐私数据库, 如图 5 所示。

文中主要使用的两种融合的交互式保护, 先将原始数据转化成转移矩阵, 根据拉普拉斯进行加噪, 再将加噪的数据作为输入数据, 进行 PersonalRank 排序, 得

到的结果再根据指数机制进行差分隐私保护。

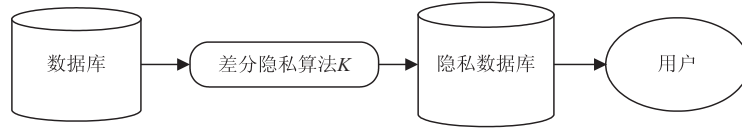


图5 非交互式框架

2 算法设计

2.1 PersonalRank 随机游走算法

得到用户物品的二分图之后,对指定用户 u 进行个性化推荐,就需要在二分图上进行随机游走^[13]。起始点为用户节点 V_u ,以 ∂ 的概率决定是否继续往下走,还是停止,从 V_u 继续重新开始走。如果是决定往下走,那就从当前节点所连接的节点中随机选择一个节点,作为下次游走的节点,继续重复这样的操作,每个物品节点就会收敛成一个稳定的概率,最后的推荐中,物品的分值就是物品节点的访问概率。以上步骤可以简化为以下公式:

$$\text{PR}(v) = \begin{cases} \partial \sum_{v' \in \text{in}(v)} \frac{\text{PR}(v')}{|\text{out}(v')|} (v \neq v_u) \\ 1 - \partial + \partial \sum_{v' \in \text{in}(v)} \frac{\text{PR}(v')}{|\text{out}(v')|} (v = v_u) \end{cases}$$

其中, $\text{PR}(v)$ 表示 v 的点击概率,就是物品 v 的分值, $\text{out}(v')$ 表示物品节点 v' 的出度, ∂ 表示留在当前的概率。

对比 PageRank 算法,PersonalRank 算法不同点只在于 r 的值不同,意思便是每次都是从目标用户节点出发,进行随机游走。PageRank 是针对所有节点,计算各点的访问概率,而 PersonalRank 算法是所有物品顶点相对于目标用户节点的概率。

PersonalRank 算法虽然能够很好地在物品二分图上进行迭代,但是因为每推荐一次,都要在整个二分图上迭代,直到整个二分图的概率稳定,使得这个过程时间复杂度较高,生成的推荐结果很耗时,同时也无法在线提供实时推荐。

为了解决整个问题,有两种方法,第一种是控制迭代的次数,设定一个指定迭代次数,在收敛之前就可以停止。但是这种方法有个问题,准确度无法保证,但是影响不大。另一种是转化成矩阵计算,将二分图转化成转移矩阵的形式,公式如下:

$$M(v, v') = \frac{1}{|\text{out}(v)|}$$

或者写成:

$$M(v, v') = \begin{cases} \frac{1}{|\text{out}(v)|} & \text{if } (j \in \text{out}(i)) \\ 0 & \text{else} \end{cases}$$

将 v 转移为 v' ,得到的是一个概率值, $|\text{out}(v)|$

是 v 的出度,是一个实数,那么 $1/|\text{out}(v)|$ 就可以表示这个节点 v 转移以后的概率矩阵。

那么,迭代公式可以转化为:

$$r = (1 - \partial)r_0 + \partial M^T r$$

解方程得到:

$$r = (1 - \partial M^T)^{-1} (1 - \partial)r_0$$

因为只看相对的大小,而取 r 中元素排序的前 k 个值,则忽略 $1 - \partial$ 的具体值,只要计算 $(1 - \partial M^T)^{-1}$ 的值,并且该式是高度稀疏矩阵,容易计算。

举个例子来说,如图6所示,将二分图转换成转移矩阵,每一列表示一个节点出边的权重,例如第一列表示节点 A 的出边,它对 a, c 两个节点分别有一条边,权重为 1/2,所以该图对应的转移矩阵如下:

$$M = \begin{bmatrix} 0 & 0 & 0 & \frac{1}{2} & 0 & \frac{1}{3} & 0 \\ 0 & 0 & 0 & \frac{1}{2} & 1 & \frac{1}{3} & \frac{1}{2} \\ 0 & 0 & 0 & 0 & 0 & \frac{1}{3} & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{4} & 0 & 0 & 0 & 0 & 0 \\ 0 & \frac{1}{4} & 0 & 0 & 0 & 0 & 0 \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{2} & 0 & 0 & 0 & 0 \\ 0 & \frac{1}{4} & \frac{1}{2} & 0 & 0 & 0 & 0 \end{bmatrix}$$

第一行是各个节点转移到节点 A 的概率,而 r 的第一列分别是各个节点当前的 PR 值,因此用 M 的第一行乘以 r 的第一列,所得结果就是节点 A 的最新 PR 值。

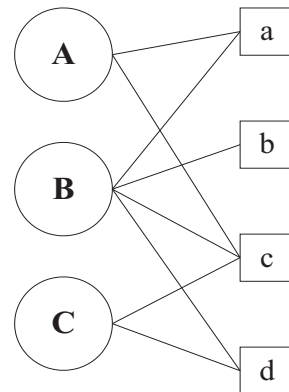


图6 二分图

2.2 融合差分隐私的模型计算

为满足差分隐私,先将数据集处理,针对二分图转化成转移矩阵,计算对应点的 PR 值,加入拉普拉斯噪声,进行 PersonalRank 随机游走,根据得到的每个物品节点的分值,筛去目标用户已经做出选择的物品。由

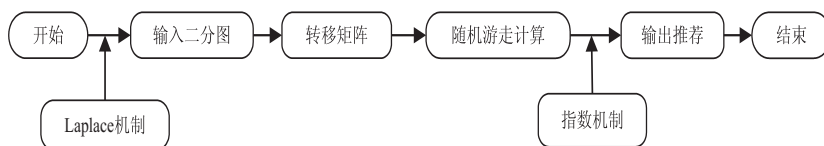


图 7 融合差分隐私流程

输入:用户物品评分和目标用户 u ;

输出:输出给目标用户的推荐物品 item。

(1)处理输入数据,转化成二分图模型;

(2)计算转移矩阵,加上拉普拉斯噪声;

(3)根据 PersonalRank 的公式计算每个节点 PR 分值;

(4)筛去用户 u 已经选择的物品,并以打分函数为 $\frac{PR(v)}{\sum(\text{top10}(PR(v)))}$,根据指数机制输出推荐结果,其中 $\Delta f = \max Pr(v) - \min Pr(v)$ 。

3 实验与分析

3.1 数据集

根据以上提出的计算方法,本节将在真实数据集上进行实验,用来验证新算法。实验结果表示不但可以进行差分隐私保护,同时也能达到一定的推荐准确率。

数据集是 ratings15000.csv,截取自 MovieLens 数据集,来自 <http://grouplens.org/datasets/movielens/>,主要结构如表 1 所示。

3.2 实验结果

实验默认迭代次数 iter_num 为 100 次,只要满足迭代条件,迭代停止。图 8 是 iter_num 随 α 变化而变

于物品数量很多,推荐结果只需要一个,可以将得到的物品分值取出 Top10,以这 10 个物品的分值作为打分函数,以满足指数机制的概率输出一个目标物品。图 7 是整体的流程图。

化的折线图,这里取 0.8,比较符合实际。

表 1 数据集结构

属性名	统计
userId	126
movieId	73 511
rating	0-5
timestamp	/

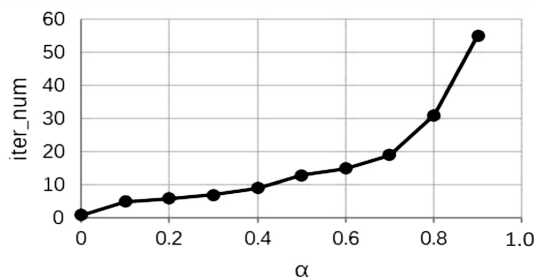


图 8 iter_num 随 α 变化而变化的折线图

另一个主要的参数是隐私保护参数 ε ,由文献 [16]可知隐私预算 ε 越大,数据可用性越高,安全性越低,当隐私预算 $\varepsilon = 0$ 时,数据失去意义。

该实验得到的结果,主要是以节点分值为打分函数,以指数概率输出,每次得到推荐物品并不一定相同,以下图标是统计分值前十的物品,在 100 次查询中,不同的隐私预算的情况被输出的次数(见图 9)。

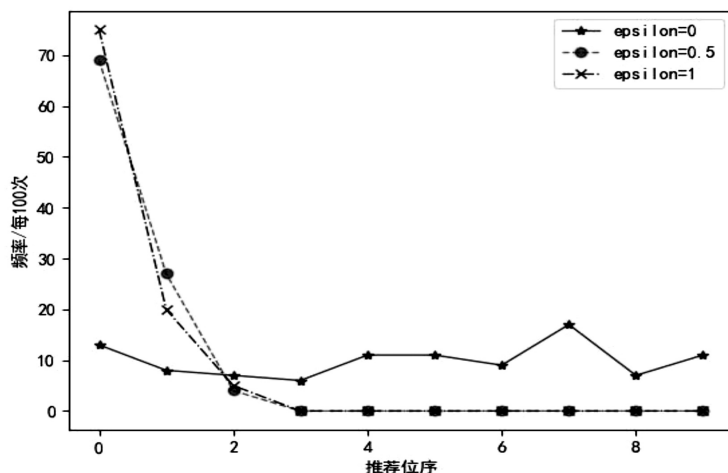


图 9 推荐位序前十物品每次输出频率

由图9可以得知,该模型能够很好地保护输出的结果,高概率的分值以指数高概率输出,低概率的分值以指数低概率输出,每次查询的结果并不一定相同,同时,由于是取的分值前十,也在一定程度上保证了推荐的准确度,同时也验证了隐私预算越大,数据可用性越高。

4 结束语

为了保证推荐结果的隐私性,通过差分隐私的拉普拉斯机制和指数机制,以 PersonalRank 都得到的分值,敏感度为最大分值减去最小分值,筛选目标用户选择的物品,取 Top10 为打分函数,以满足差分隐私的概率输出推荐物品。该模型每次输出的推荐结果不一定相同,分值高的节点输出概率更高,因为满足指数机制,可以保证攻击者不会通过查询作差得到目标用户或者其他用户对物品的行为。但是该模型针对大型网络图数据迭代时间复杂度过高,应用中需要根据实际情况选择。

参考文献:

- [1] GROH G, EHMIG C. Recommendations in taste related domains[C]//Proceedings of the 2007 international ACM conference on supporting group work. New York, USA: Association for Computing Machinery, 2007: 127-136.
- [2] 何凌云, 洪良怡, 周洁, 等. 社交网络隐私安全研究综述[J]. 信息技术, 2018(5): 153-159.
- [3] DWORK C, KENTHAPADI K, MCSHERRY F, et al. Our data, ourselves: privacy via distributed noise generation[C]//Advances in Cryptology - EUROCRYPT 2006. St. Petersburg, Russia: Springer-Verlag, 2006: 486-503.
- [4] DWORK C, MCSHERRY F, NISSIM K. Calibrating noise to sensitivity in private data analysis[M]//Theory of cryptography. Berlin, Heidelberg: Springer, 2006: 637-648.
- [5] DWORK C, NAOR M, PITASSI T, et al. Pan-private streaming algorithms[C]//The first symposium on innovations in computer science. Beijing, China: Tsinghua University Press, 2010: 66-80.
- [6] DWORK C. A firm foundation for private data analysis[J]. Communications of the ACM, 2011, 54(1): 86-95.
- [7] NOVAC O C, NOVAC M, CORDAN O, et al. Comparative study of Google, Android, Apple iOS and Microsoft windows phone mobile operating systems[C]//International conference on engineering of modern electric system. Oradea, Romania: IEEE, 2017: 154-159.
- [8] SILVA M R D, ROMOS T M, HOLANDA M T D. Geographic information system with public participation on IoT system[C]//Information systems and technologies. Lisbon, Portugal: IEEE, 2017: 1-5.
- [9] PIHUR V, KOROLOVA A. RAPPOR: randomized aggregatable privacy-preserving ordinal response[C]//ACM SIGSAC conference on computer and communications security. [s.l.]: ACM, 2014: 1054-1067.
- [10] FANTI G, PIHUR V, ULFAR E. Building a RAPPOR with the unknown: privacy-preserving learning of associations and data dictionaries[J]. Proceedings on Privacy Enhancing Technologies, 2016(3): 41-61.
- [11] 项亮. 推荐系统实践[M]. 北京: 人民邮电出版社, 2012.
- [12] 热情的沙漠. 《推荐系统实战》-笔记与思考[EB/OL]. [2017-07-09]. <https://www.cnblogs.com/buptzym/p/7140639.html>.
- [13] 刘清, 王帆, 冯亮, 等. 高效图推荐算法应用研究[J]. 软件导刊, 2019, 18(8): 49-51.
- [14] 李杨, 温雯, 谢光强. 差分隐私保护研究综述[J]. 计算机应用研究, 2012, 29(9): 3201-3205.
- [15] 李效光, 李晖, 李风华, 等. 差分隐私综述[J]. 信息安全学报, 2018, 3(5): 92-104.
- [16] 王俊丽, 管敏, 魏绍臣. 面向社交网络分析的差分隐私保护研究综述[J]. 高技术通讯, 2015, 25(3): 239-248.