

文章编号:1007-5321(2020)01-0008-06

DOI:10.13190/j.jbupt.2019-061

基于链路预测的手机节能方法

徐九韵¹, 孙忠顺², 张如如³

(1. 中国石油大学(华东) 计算机科学与技术学院, 青岛 266580; 2. 中国石油大学(华东) 海洋与空间信息学院, 青岛 266580;
3. 中移(苏州) 软件技术有限公司, 苏州 215010)

摘要: 移动云计算为部署大量移动服务提供了技术支持,但用户在不稳定的通信条件下访问云资源往往需要大量的能耗,制约了移动云计算的广泛应用. 对此,提出了基于用户交互行为最大化的链路预测方法. 首先在数据预测模型的基础上利用基于互动关系改进的交互度方法对已知用户访问的数据进行预测;再结合基于用户行为的社交网络 Friendlink 方法对预测数据进行数据分析筛选,利用数据预存储机制来预存上述预测数据. 实验结果表明,在保证不涉及用户隐私信息,并提高用户下次访问命中率的情况下,达到了预期的手机节能目的.

关键词: 手机节能; 访问数据预测; 社交网络; 互动次数

中图分类号: TN929.53

文献标志码: A

Mobile Phone Energy Saving Based on Link Prediction

XU Jiu-yun¹, SUN Zhong-shun², ZHANG Ru-ru³

(1. College of Computer Science and Technology, China University of Petroleum, Qingdao 266580, China;
2. College of Oceanography and Space Informatics, China University of Petroleum, Qingdao 266580, China;
3. The China Mobile (Suzhou) Software Technology Company, Suzhou 215010, China)

Abstract: The technology of mobile cloud computing is benefit for deploying various mobile applications. However, there is an energy consumption problem to access cloud resources via mobile phone, which needs to establish connections many times under unstable communication conditions. To solve this problem, a link prediction method based on maximum user interaction behavior was proposed. Firstly, based on data prediction model, an interaction degree method based on improved interaction relationship is used to predict the data accessed by users. Then, combined with the friend link method of social network based on user behavior, the prediction data is analyzed and filtered, and the pre-storage mechanism is used to pre-store the above prediction data. Experiments show that the expected energy saving of mobile phones can be achieved without involving users' private information and improving the hit rate of users' next visit.

Key words: smartphones save energy; access data prediction; social network; interaction times

移动云计算是一种将移动互联网与云计算相结合的新技术,用户可将数据的计算和存储等工作迁移至云端来克服其移动终端处理能力弱、存储空间小等缺点. 从移动互联网和云计算的特征看,可以将移动终端和云计算设备两者结合起来,手机的任务是交互,复杂的计算则由云端来完成,利用云计算改善移动端的局限性. 因此,用户将移动云计算的

云端作为服务中心,移动终端不需要拥有强大计算存储能力便可为用户提供所需的服务. 研究表明,移动云计算中与服务器建立数据连接、数据传输时能量消耗较多,这是导致智能手机能耗过快的主要原因. 笔者将相似用户访问数据的相似性和用户行为数据的可预测性这2个因素考虑在内,提出了基于用户交互行为最大化的链路预测方法(LP-

收稿日期: 2019-04-21

作者简介: 徐九韵(1966—),男,教授, E-mail:jyxx@upc.edu.cn.

MUIB, link prediction method based on maximum user interaction behavior).

1 相关工作

针对电池耗电过快的问题,国内外专家学者从不同的角度对移动终端节能技术展开了研究.

Muharum 等^[1]提出了 Android 操作系统的节能应用程序接口 (API, application programming interface),将应用程序转变为能量感知应用程序以实现节能. Eom 等^[2]研究了云环境下能源消耗与各种编码类型之间的相关性,并提出了一种基于功率感知的编码方案,最大限度地延长移动终端的续航时间.

为了改善移动应用的性能,一些学者引入计算迁移的概念. Mazza 等^[3]在移动终端满足执行时间合理的基础上实现了最小化耗能的目的. Gu 等^[4]开发了一个自适应的迁移系统,但是需要修改 Java 虚拟机来支持对象在智能手机和服务器的透明迁移.

殷波等^[5]针对当前虚拟机迁移方法考虑了迁移成本或者由应用相关性带来的虚拟机之间的通信成本,提出了一种虚拟机迁移策略,以实现数据中心节能的目标,并且综合考虑了迁移成本和通信成本. 王安^[6]将移动终端节能技术与移动网络技术相结合,对移动终端数据传输过程中的能量消耗进行了深入分析.

2 LP-MUIB

所提出的 LP-MUIB 方法分为 2 个阶段:① 交互行为最大化阶段. 提出基于用户交互行为的影响最大化方法. ② 链路预测阶段. 提出一种基于互动关系随机游走的算法.

2.1 基于 LP-LUIB 节能框架模型

移动云计算下用户访问数据预测的手机节能模型框架如图 1 所示,在现有云服务器中增加交互关系最大化和社交网络链路预测模块. 框架的核心是服务器端用户数据预测模块,它的主要任务是:当用户通过手机向云服务器查询数据时,通过服务器数据预测模块查询出用户的历史访问数据和社交活动,再利用所提出的 LP-MUIB 方法预测当前用户将未来可能再次访问的数据预存到手机端,降低因通信环境差与云端进行的多次交互.

2.2 基于用户交互行为的影响最大化方法

步骤 1 构建邻居组,计算交互度

当用户 u 向服务器发起请求时,根据该用户和

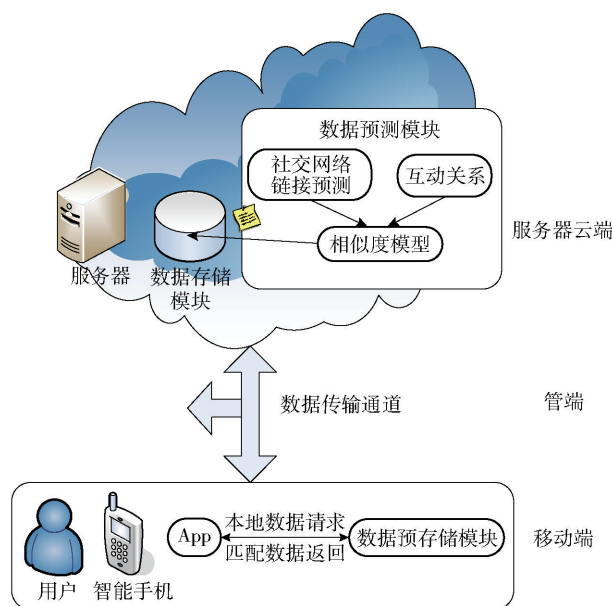


图 1 移动云计算下用户访问数据预测的手机节能策略模型

邻居用户交互次数历史数据信息 $Inter$, 构建邻居组. 采用改进的交互度方法计算邻居组中各个邻居对目标用户的交互度. 用户 u 与 v 的互动次数表示为 $I(u, v)$.

基于用户间相互影响力和接触次数 (W) 的考虑,给出用户交互度的计算公式:

$$T(u, v) = \sqrt{W_{uv} + W_{vu}} + \sqrt{W_{uv} + W_{vu} - |W_{uv} - W_{vu}|} \quad (1)$$

文中朋友关系是无向的,则用户之间交互度的公式为

$$T(u, v) = 2 \sqrt{I(u, v)} \quad (2)$$

步骤 2 计算基于交互行为的社交影响力

基于式(1)得出的邻居组中邻居用户与目标用户的交互度,不能直接用于评估用户之间的影响力. 因为在实际情况下,邻居用户对目标用户的影响力不只是互动关系,还包括朋友关系. 一般情况下,好友的数目与互动次数 $I(u, v)$ 之间的关系不具规律性,而且不是一个量级,因此无法直接计算朋友关系和互动关系对目标用户的影响,需要对互动次数做一定比例换算,即

$$S(u, v) = T(u, v) \frac{W_{uv}}{\sum_{w \in N(v)} W_{vw}} = T(u, v) \frac{I(u, v)}{W_v + W_u} \quad (3)$$

其中: $S(u, v)$ 表示用户 u 与用户 v 之间通过交互行为对彼此的影响力, $T(u, v)$ 表示式(2)计算的交互

度, $N(v)$ 表示用户 v 的邻居集, W_{uv} 为 2 个用户的交互次数.

从式(3)中可以看出, W_{uv} 代表的 2 个用户的交互次数对 $S(u, v)$ 起决定作用, 能够计算出具体数值, 衡量用户之间基于交互行为的影响力. $S(u, v)$ 越大, 表示 u, v 之间关系亲密度越高, 用户 u 就越可能访问到用户 v 的历史数据; $S(u, v)$ 越小, 表示 u, v 之间的亲密度越低, 用户 u 访问用户 v 的历史数据的可能性越低. $S(u, v)$ 对用户历史访问数据信息进行归一化计算后, 基于用户交互行为的影响最大化算法如算法 1 所示.

算法 1 交互影响力算法

输入: 用户交互行为信息 $Q = \{id, data, Inter, friend\}$

输出: S

```

1 for  $Q$  do
2  $G = (V, E, W)$  undirected graph  $\leftarrow Inter, friend$ ;
3   for  $q_i \in Q, I_i \in Inter$ 
4     if  $I_i > 0$ 
5       构建邻居组  $Q_k$ ;
6   for  $u_i \in U$  do
7     for  $u_j \in Q_k$  do
8        $T(u_i, u_j) \leftarrow I(u_i, u_j)$ ;
9   for  $u_i \in U$  do
10     for  $u_j \in Q_k$  do
11       calculate  $S(u_i, u_j) \leftarrow T(u_i, u_j)$ ;
12 return  $S$ 

```

首先根据数据库中用户历史互动行为信息 Q 构造社交网络无向图 G , 进而通过 Q 中 $Inter$ 寻找各用户与目标用户之间的互动次数. 若 $I_i > 0$, 代表用户与目标用户之间存在互动关系, 将用户 u_j 加入邻居组 Q_k 中; 若 $I_i = 0$, 代表用户与目标用户之间不存在互动关系, 放弃用户 u_j . 算法第 6 ~ 11 行表示利用邻居组 Q_k 中各个邻居与目标用户之间的互动次数 $I(u_i, u_j)$ 计算各个邻居与目标用户的交互度 $T(u_i, u_j)$ 以及相应的交互影响力 $S(u_i, u_j)$, 为下一阶段基于互动关系随机游走的方法做准备.

2.3 基于互动关系随机游走的链路预测

2.3.1 基本思想

链路预测推荐方法的关键是计算用户间的相似度, 相似度越高的邻居用户的访问数据越可能作为目标用户下一步要访问的数据. 用户间的相似性具有媒介性、衰弱性、共同好友性和发散性等特征, 如

图 2 所示.




图 2 用户相似性特征

针对朋友选择问题, 通过对社交网络 FriendLink 方法进行分析, 基于用户行为引入互动关系, 以识别社交网络中的不同相关强度的朋友, 形成权重社会网络, 提出一种基于互动行为局部随机游走的推荐方法, 其基本流程如图 3 所示.

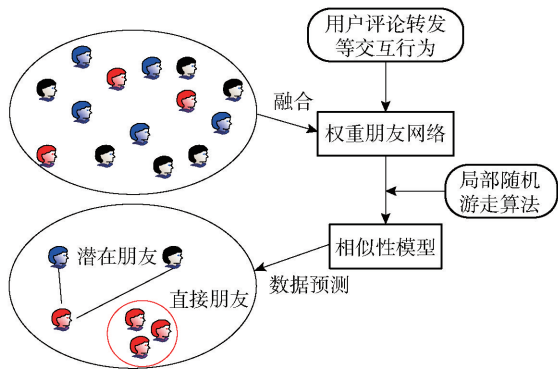


图 3 随机游走流程

随机游走包括 2 个步骤: ① 通过朋友关系与互动行为, 分析出带权的关系网络; ② 在包含互动次数的关系网络上, 利用基于互动行为改进的偏向相似度高节点游走方法计算邻居与目标用户 u 的相似度, 取得 TOP K 个用户数据作为用户 u 即将要访问的数据.

2.3.2 方法描述

步骤 1 分析相关强度

根据图的连接理论定义社会网络为 $G = (U, E)$. 其中 $u_i, u_j \in U$, 若 2 个顶点 u_i 和 u_j 之间存在朋友关系, 即通过边建立连接, $(u_i, u_j) \in E$, 则 $a_{ij} = 1$; 否则为 0. 因此能够用对称的邻接矩阵 $A = (a_{ij}) \in \{0, 1\}$ 表示无向无权社交网络. u_i 的邻居集合表示为 $\Gamma(u_i) = \{u_j | (u_i, u_j) \in E\}$, u_i 与 u_j 的互动次数表示为 $I(u_i, u_j)$.

具体地, 仅仅考虑朋友网络, 用户 u_i 和 u_j 的朋友关系强度 W_{ij} 如式(4)所示. 用户 u_i 和 u_j 间的共同朋友数量起决定作用.

$$W_{ij} = \begin{cases} |\Gamma(u_i) \cap \Gamma(u_j)| + 1, & (u_i, u_j) \in E \\ 0, & (u_i, u_j) \notin E \end{cases} \quad (4)$$

根据用户间共同朋友数目的多少和互动次数来表示他们之间朋友关系的强弱,改善网络拓扑结构的实际准确性. 通常情况下,若用户更加关注某用户的数据信息,则该用户更可能会选择此数据作为接下来要访问的数据. 若考虑用户个性化行为的互动次数,关系强度会向用户行为方向变化. 如式(5)所示,用户 u_i 和 u_j 的相关强度 W_{ij} 由两者间媒介数量与基于交互行为的相互影响力之和共同决定.

$$W_{ij} = \begin{cases} |\Gamma(u_i) \cap \Gamma(u_j)| + 1 + S(u_i, u_j), & (u_i, u_j) \in E \\ S(u_i, u_j), & (u_i, u_j) \notin E \end{cases} \quad (5)$$

这样,基于交互行为的互动关系影响力强弱会对相关性产生较大影响,更加符合实际用户行为. 因此能够用对称的邻接矩阵 $A' = (a'_{ij})_{n \times n}$ 表示本研究的无向权重社交网络,其中 $a'_{ij} = w_{ij}$.

步骤2 计算相似度

如图2所示,根据数据库中历史互动次数 $I(u, v)$ 计算出 $S(u, v)$, 即 $S(u_1, u_2) = 1; S(u_1, u_3) = 3; S(u_1, u_4) = 4; S(u_2, u_3) = 2; S(u_2, u_4) = 1; S(u_3, u_4) = 2$, 则此局部权重社交网络的对称邻接矩阵 A' 应表示为

$$A' = \begin{bmatrix} 0 & 2 & 4 & 4 \\ 2 & 0 & 4 & 3 \\ 4 & 4 & 0 & 4 \\ 4 & 3 & 4 & 0 \end{bmatrix}$$

由于在社会网络中,比起认识的朋友,用户更可能选择相关强度高的朋友的历史访问数据作为将要访问的数据. 关系亲密的朋友可能不是直接朋友,有可能是互动关系强的潜在朋友,因而游走者需要考虑互动行为影响力,不再像简单拓扑结构那样等概率地游走. 局部随机游走过程可以使用转移概率矩阵来描述,其元素为

$$q'_{ij}(t) = \frac{w_{ij}}{\sum_{u_k \in \Gamma(u_i)} w_{ik}} \quad (6)$$

表示随机游走者选择从顶点 u_i 到 u_j 的概率,等比于基于互动关系的相关强度. 这样,游走者选择方向的概率更偏向互动关系强的用户,进而 u_i, u_j 的相似度可以通过游走者从起始点 u_i 经历多次路径到达 u_j 的概率来计算,称之为 $\text{sim}(u_i, u_j)$.

$$\text{sim}(u_i, u_j) = \sum_{a=1}^b \prod_{t=2}^l q'_{ij}(t) \quad (7)$$

其中: b 为 u_i 与 u_j 之间可能的路径个数; t 为在某一

路径内第 t 个步骤; l 为游走者游走路径长度,即总步骤数.

例如,图2(a)中,目标用户是 u_2 , 通过对称邻接矩阵 A' 计算转移概率矩阵 Q' 的元素 $q'_{ij}(t)$, 得到 $\text{sim}(u_2, u_1) = 2/(2+4) = 0.3$, $\text{sim}(u_2, u_3) = (2/2+4)/(4/2+4) = 0.83$.

与 u_3 相比, u_1 与 u_2 的相似性更强, u_1 的访问数据更有可能作为目标用户 u_2 的预测访问数据. 因此,核心算法只涉及用户历史访问数据,互动关系是用户相似性的基础. 根据用户间互动次数分析得出用户之间基于交互行为的影响力相对数值 $S(u_i, u_j)$; 再根据用户朋友关系对相关强度进行归一化数值计算,得到相关强度 W_{ij} , 进而分析用户与目标用户的相似度,预存储相似度高的用户数据. 基于交互关系的随机游走算法如算法2所示.

算法2 基于交互关系的随机游走算法

输入: U_n : The known user set; I : User interactions

输出: Top K

```

1 for  $u_i \in U$ ,  $I_i \in I$  do
2    $UI$  undirected graph  $\leftarrow I_i, u_i$ ;
3 while true do
4   for  $u_i \in U$  do
5     for  $u_j \in U$  do
6        $w[i][j] \leftarrow \Gamma(u_i) \cap \Gamma(u_j) + S(u_i, u_j)$ ;
7     for  $u_i \in U$  do
8       for  $u_j \in U$  do
9          $q[i][j] \leftarrow w_{ij}, \Gamma(u_i)$ ;
10      calculate  $q'_{ij}(t)$ 
11  $\text{sim}[i][j] \leftarrow w_{ij}$ ;
12 calculate  $\sum_{a=1}^b \prod_{t=2}^l q'_{ij}(t)$ ;
13 return Top  $K$   $\text{sim}[i][j]$ 
```

算法2中,第1~2行表示根据云数据库中用户历史访问数据信息得到带权值的社交网络无向图;第3~6行表示若 $S(u_i, u_j) > 0$, 结果是 true 时,代表用户与目标用户之间存在互动关系,结合朋友关系 $\Gamma(u_i)$ 和 $\Gamma(u_j)$ 计算相关强度;第7~11行表示利用随机游走到不同邻居的概率 $q'_{ij}(t)$ 计算各个邻居与目标用户的相似度 $\text{sim}(u_i, u_j)$, 将取得的相似度最高的 Top K 个用户的访问数据作为目标用户的预访问数据存储到本地缓存器中.

3 手机终端预存储模型

3.1 移动终端预存储模块

云端数据预测模块预测出目标用户可能感兴趣的数据,存入手机端数据预存储模块中. 手机内部 API 搜索数据预存储模块中的关键字算法如算法 3 所示.

算法 3 数据预存储模块中的数据匹配算法

输入: K : Search keyword; $\text{Map} \langle \text{key}, \text{word} \rangle$:

Data set in data pre-storage modular

输出: Relevant data RD with keyword

```

1 if Map contains Key  $K$  then
2   internal API;
3   search RD by local  $k$ ;
4   if Map. get( $K$ ) then
5     RD ← GetRD( $K$ );
6 else
7   external API;
8   select data RD from the Server;
9 return RD
  
```

当用户再次通过客户端访问相似数据时,执行算法 3. 第 1~5 行表示查找数据预存储模块的本地文件,若能匹配到关键字 K ,则通过 getRD 将查找到的数据直接返回;第 6~8 行表示若本地文件中查询不到关键字 K ,则需要再到云服务器中查找相关信息.

3.2 预存储数据容量与手机耗能关系

为了使本地缓存既能满足预存储又能实现节能的目的,找到手机耗能与预存取数据量大小之间的关系非常重要.

根据基于用户交互行为的最大化模型,可以得到邻居组 Q_k 中各用户对目标用户 u 的影响力 $S(v_n, u)$, v_n 表示目标用户 u 的 n 个邻居朋友. $S(v_n, u)$ 越大,代表邻居用户 v_n 与目标用户之间受到彼此影响越大,目标用户越可能访问邻居用户的历史数据. 因此,使用 $S(v_n, u)$ 衡量预存储数据选择方向就有合理性,满足预存储命中率高的要求.

每个 v_n 用户在服务器端数据库中的访问数据量不尽相同,用 Size_n 表示. 依据算法 3,用户再次访问 App,通过关键字 $\text{Map} \langle \text{key}, \text{word} \rangle$ 从缓存中查询所需要的数据. 若用户 v_n 已被选作目标用户 u 的预存储数据用户,但其访问数据量 Size_n 较大,全部预

存储数据会有不必要的能耗,因此,需要对 TOP K 用户的 Size_n 添加约束,实现节省预存储能耗的目的. 这样,将朋友对目标用户的社交影响力 $S(v_n, u)$ 与其朋友访问数据量大小 Size_n 相结合,使数据预测模型的实现更具有准确性和合理性. 计算公式如下:

$$\text{Data Size}(u) = \sum_{n \in \bar{K}} \mu \times S(v_n, u) \times \text{Size}_n \quad (8)$$

其中: \bar{K} 为根据随机游走算法得到的相似度最高的 Top K 个用户, μ 为对 TOP K 用户的 Size_n 约束系数, v_n 为相似用户. 预存储模块的数据量大小 $\text{Data Size}(u)$ 取决于 TOP K 中朋友关系的社交影响力和每个 Top K 用户访问数据量大小的乘积.

4 实验分析

实验数据集选用腾讯微博中的部分数据,包括朋友关系、互动关系及用户访问数据. 本实验使用的测量耗能的工具是 PowerTutor 软件. Android 实验机型号是 Letv X500,系统版本为 6.0.

依据数据集,从输入目标用户开始,只考虑用户之间的好友关系,采用宽度优先策略收集用户好友关系. 通过用户表中 relation 字段首先模拟一个小型的社交网络;随后根据好友列表分别从用户互动行为和用户访问信息中提取出节点用户 interaction 和 data 字段数据,获得相关用户的社交行为. 根据拓扑结构获得用户间媒介点数量,结合互动行为的最大化影响,利用媒介和交互影响力计算相似度,获得相似度最高的 TOP K 个用户.

4.1 TOP K 数据分析

如何确定 K 的值是解决预存取数据量大小与手机耗能之间关系的关键. Top K 推荐中评价指标如下:

$$\text{准确率} = \frac{K \text{ 中已经是好友的用户数}}{K} \quad (9)$$

$$\text{召回率} = \frac{K \text{ 中已经是好友的用户数量}}{\text{目标用户的好友数量}} \quad (10)$$

所提出的 LP-MUIB 方法通过改变 K 值得出 TOP K 与准确率和手机耗能关系曲线,如图 4 所示.

4.2 预存储模块容量的数据分析

确定 TOP K 的值还不能确定预存储数据容量和手机耗能之间的关系,需要确定预存储值的大小与移动端耗电关系. 根据式(8)所示的预存储数据容量与手机耗能之间的数量关系,在本实验中,目标用户所有朋友的访问数据容量设为 10 MB,获得的




图 4 TOP K 曲线

缓存数据量如图 5 所示. 由图 4 和图 5 得出, K 取 5, 缓存的数据量为 60, 为本实验中的最佳值.




图 5 数据容量与耗电关系曲线

4.3 对比实验

4.3.1 比较方法

1) LP-MUIB. 基于以上设定的预存储模块的容量开展实验对比. 一组直接从服务器获取数据, 另一组增加手机数据预存储模型, 模拟正常网络和不稳定 2 种环境, 其中第 4 次为通信不稳定环境.

2) 手机节能策略^[7] (SP-EES, smartphone energy-efficiency strategy). 该方法基于混合变量属性 k -

means 算法对已知用户进行聚类分组, 建立相似用户群, 利用模型对用户连续搜索进行预测.

3) 应用层传输协议^[8] (APPATP, application-layer transmission protocol). 该方法受到预取友好和延迟容忍应用普及的推动, Liu 等^[8] 设计并实现了 APPATP. 该协议利用云计算管理移动应用数据的传输, 以节能的方式, 与移动设备进行数据的互传.

4.3.2 实验评估

将 LP-MUIB 与 SP-EES 方法进行比较, 如图 6 所示. 该实验为手机耗能与访问次数的关系, 其中横轴为访问的次数, 纵轴为耗电量. 由图 6 可以看出, 所提出的 LP-MUIB 方法可进一步节约能耗, 能耗降低了 15% ~ 25%.




图 6 实验耗能结果对比

将 LP-MUIB 与 APPATP 方法进行了比较, 如图 7 所示, 其中横轴为手机预存储量, 纵轴为耗电比, w/o-APPATP 为 APPATP 的基准实验. 由图 7 可以看出, 所提出的 LP-MUIB 方法较 APPATP 在节能方面有一定的提高.




图 7 实验耗能与手机预存储容量对比

- cation and mitigation for geolocation using least-squares support vector machines[C]//2017 IEEE Wireless Communications and Networking Conference (WCNC). New York: IEEE Press, 2017: 1-6.
- [7] Yan Jun, Wu Lenan. A data fusion scheme for modified EKF banks positioning algorithm in mixed LOS/NLOS conditions[C]//12th IEEE International Conference on Ubiquitous Intelligence and Computing and 15th IEEE International Conference on Autonomic and Trusted Computing and 15th IEEE International Conference on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom). New York: IEEE Press, 2015: 1249-1252.
- [8] Zhang Lan, Chen Feng, Yu Yao. Research on hybrid location algorithm with high accuracy in indoor environment[C]//34th Chinese Control Conference. New York: IEEE Press, 2015: 15454267.
- [9] Hu Nan, Wu Chengdong, Li Chen, et al. The NLOS localization algorithm based on the linear regression model of extended Kalman filter[J]. Journal of Image and Graphics, 2016, 4(2): 141-144.
- [10] Wang Hongwei, Li Hongbin, Zhang Wei, et al. A unified framework for M-estimation based robust Kalman smoothing[J]. Signal Processing, 2019, 158: 61-65.

(上接第 13 页)

5 结束语

针对预存储数据选择方面,提出 LP-MUIB 方法,在原有数据预存储节能模型基础上增加社交网络与互动关系,用以提高用户下次访问的命中率. 为了不涉及用户背景等隐私信息,提出一种基于用户交互行为的影响最大化方法,利用基于互动关系改进的交互度方法对已知用户访问数据预测,并在该方法的基础上提出一种基于互动关系随机游走的算法,对预测数据进行筛选,为用户返回尽可能准确的预测结果. 最后通过实验验证该方法在节能方面有一定效果. 下一步工作将研究重点放在预存储模块缓存期存活时间设置上,如何计算相应的阈值,实现数据更新,进一步提高预测的准确率.

参考文献:

- [1] Muharum A M, Joyejob V T, Hurbungs V, et al. Ener-save API: android-based power saving fram-ework for mobile devices[J]. Future Computing and Informatics Journal, 2017, 2(1): 48-64.
- [2] Eom B, Lee C, Lee H, et al. An adaptive remote display scheme to deliver mobile cloud services [J]. IEEE Transactions on Consumer Electronics, 2014, 60(3): 540-547.
- [3] Mazza D, Tarchi D, Corazza G E. A partial offloading technique for wireless mobile cloud computing in smart cities[C]//European Conference on Networks and Communications. [S. l.]: IEEE, 2014: 1-5.
- [4] Gu X, Messer A, Greenberg I, et al. Adaptive off-loading for pervasive computing[J]. IEEE Pervasive Computing, 2015, 3(3): 66-73.
- [5] 殷波, 王颖, 孟洛明, 等. 综合迁移成本和通信成本的云计算节能策略[J]. 北京邮电大学学报, 2012(1): 68-71.
- Yin Bo, Wang Ying, Meng Luoming, et al. A new virtual machine migration strategy based on migration cost and communication cost for power saving in cloud[J]. Journal of Beijing University of Posts and Telecommunications, 2012(1): 67-71.
- [6] 王安. 面向节能的移动网络传输关键技术研究[D]. 北京: 北京邮电大学, 2013.
- [7] 徐九韵, 管超, 杨丹, 等. 一种基于协同过滤与 BG/NBD 模型数据预测的智能手机节能策略[J]. 计算机集成制造系统, 2017, 23(5): 1139-1146.
- Xu Jiuyun, Guan Chao, Yang Dan, et al. Smartphone energy-efficiency strategy based on collaborative filtering and BG/NBD model[J]. Computer Integrated Manufacturing Systems, 2017, 23(5): 1139-1146.
- [8] Liu Fangming, Shu Peng. AppATP: an energy conserving adaptive mobile-cloud transmission protocol[J]. IEEE Transactions on Computers, 2015, 64(11): 3051-3063.