

一种基于事件的Lifelog管理模型

陈亮¹, 杨建常^{2*}, 刘国奇¹, 张立波³

¹沈阳建筑大学计算机科学与工程学院, 辽宁 沈阳

²32683部队, 辽宁 沈阳

³中国人民解放军北部战区总医院, 放射科, 辽宁 沈阳

收稿日期: 2023年12月16日; 录用日期: 2024年1月15日; 发布日期: 2024年1月23日

摘要

从2011年开始, 我们发起了一个LiuLifelog项目, 该项目收集了22位志愿者的3万条lifelogging数据。但是随着时间的推移, 用户的lifelogging数量越来越多, 管理这些数据对于用户来说变得越发复杂。为此, 本文提出了一种LE-PDA模型, 该模型将lifelogging数据划分为不同的事件, 同时为每一个事件添加了标签, 方便用户管理数据。在本次实验中, 两位用户的数据在应用LE-PDA模型后, 分别被划分为5215个和1086个带有标签的事件, 且准确率达到了68%。实验证明了LE-PDA模型在LiuLifelog数据集上的实用性, 它能帮助用户更高效的组织和管理lifelogging数据。

关键词

Lifelogging, 生活事件, 数据挖掘, 数据管理

A Lifelog Management Model Based on Events

Liang Chen¹, Jianchang Yang^{2*}, Guoqi Liu¹, Libo Zhang³

¹School of Computer Science and Engineering, Shenyang Jianzhu University, Shenyang Liaoning

²32683 Troop, Shenyang Liaoning

³Department of Radiology, North General Hospital of the People's Liberation Army, Shenyang Liaoning

Received: Dec. 16th, 2023; accepted: Jan. 15th, 2024; published: Jan. 23rd, 2024

Abstract

Since 2011, we have initiated the LiuLifelog project, which has collected 30,000 lifelogging data entries from 22 volunteers. However, as time progresses, the quantity of users' lifelogging data increases, making the management of these data increasingly complex for the users. To address this, this paper proposes a LE-PDA model, which segments lifelogging data into distinct events, while assigning labels to each event, facilitating user data management. In this experiment, the data from two users were divided into 5,215 and 1,086 labeled events respectively, after applying the LE-PDA model, achieving an accuracy rate of 68%. The experiment validates the efficacy of the

*通讯作者。

LE-PDA model on the LiuLifelog dataset, demonstrating its ability to assist users in organizing and managing lifelogging data more efficiently.

Keywords

Lifelogging, Life Events, Data Mining, Data Management

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

人们总想着通过某些方式来记录生活中的美好瞬间。早在上世纪 20 年代, Buckminster Fuller 就开始用剪贴簿来记录生活中的日常, 到了上世纪 90 年代时, Steve Mann 通过摄像机拍摄照片来记录自己的生活经历[1]。近年来, 随着可穿戴设备和定位系统的发展, 记录个人活动的方式发生了改变, 人们开始用数据来记录生活中的细节。这些数据包含人的生活数据, 健康数据, 我们称这类数据为 PBD (Personal Big Data) [2]。PBD 具有隐私性, lifelogging 就是 PBD 的一个典型代表。

lifelogging 数据是个人在日常生活中的生活经历和行为创建的个人数据, 其中包括了位置[3]、行为[4]、音频[5]和图片[6]等。这些数据揭示了一个人在何时何地发生了哪些事情, 通过对数据的进一步分析, 我们还能够分析用户的日常行为[7] [8] [9]。过去几年间, lifelogging 受到了研究人员和商业公司的广泛关注, lifelogging 也逐渐成为了一个新兴的研究领域, 一些关于 lifelogging 的社会应用也随着发展, 如运动数据分析[10] [11]、数字医疗[12] [13]、智能家居[14] [15]等。

随着移动设备和传感器技术的进步, 越来越多的数据被存储到时空数据库中。这些数据中隐藏着大量的信息, 比如吃饭、上班和到公园游玩等[16]。如何从帮助用户管理海量的 lifelogging 数据是 lifelog 研究面临的重大挑战之一。对于少量的数据, 用户可以逐个的查看这些 lifelogging 找到需要的内容。但是当数据量过多时, 用户就需要一个合适的方法帮助他们管理这些数据。文献[17]提出了一种基于集群层次结构在图中排列数据的方法。Hwang 等人[18]提出了一种基础机器学习管理数据的方式, Kim 等人[19]提出了一种分层化数据记录方式。

来自“国立台湾大学”的学者颜安孜在 2019 年将 lifelogging 中的事件识别问题列为 lifelog 领域十大问题之一[20]。本文将在此基础上进行思考, 我们是否可以将 lifelogging 划分为不同的事件, 从而有效的管理数据。在本文中, 我们提出了 LE-PDA 模型, 该模型采用分层事件挖掘, 分别对城市级数据和区域级数据进行挖掘。除此之外, 我们还对每个事件进行了添加了标签, 用户可以通过事件标签更好地管理自己的 lifelogging 数据。对于数据上传者来说, 这是一项非常有意义的工作。

本文的章节总共分为 6 节, 本节为绪论。第二节介绍了作者 11 年间收集的 LiuLifelog 数据集, 并引入了“域”的概念, 同时说明了实验的目标。第三节阐述了如何使用 LE-PDA 模型找到用户数据中的生活事件。第四节对模型的实验结果进行性能对比和分类。第五节建立可视化系统, 用以展示生活事件。最后一节对实验进行总结, 并展望未来的研究方向。

2. 相关工作

2.1. LiuLifelog 数据集

LiuLifelog 数据集(<http://www.lifelog.vip/>)是 Liu 团队花费 12 年时间记录的数据。该数据集有以下优

势：采样时间长，参与者人数众多，数据分布于全国各个城市且持续更新。每天有十几名用户分享他们的日常生活，使这个数据集成为生活日志数据的综合存储库。其中部分数据如表 1 所示。

Table 1. Sample data
表 1. 数据样例

时间	经度	纬度	行为	地点
2011-11-05 10:23	123.40287	41.76356	Communication	沈阳市沈水路
2015-05-15 08:38	123.42002	41.76417	Working at school	和平区南湖街东北大学
2017-02-15 06:12	139.73930	35.67481	Working outside	日本东京中央东京都中央区
2019-05-20 07:38	123.51115	41.74340	Teaching	沈阳市东陵区文汇街
2022-02-10 13:05	124.42730	45.22289	Tourism	前郭勒罗斯蒙古族自治县青山大道

我们的数据是非连续性的，每一条 lifelogging 包含 GPS 数据、文字描述、录音、图片或者视频文件等，并且在上传数据的时候对每一条 lifelogging 进行了行为分类标注，行为分类是事先定义好的，例如：讲课、吃饭、工作、旅行等 15 个类别。

2.2. 实验目标

在 Lifelog 中，生活事件可以划分为两种类型。第一种是独立的事件，它们通过单条数据记录表示。例如，“我去餐厅吃饭”或“准备去公司上班”等。第二种是连续的事件，它们由一系列数据记录共同构成。图 1 展示了一个连续的生活事件。





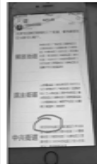

Event		
data1	data2	data3
 <p>Time: 2022-05-07 13:45:55 Text: A relaxed day, Set up tents in mozishan Park and children play. Longitude: 123.484451 Latitude: 41.672489 Behavior: Tourism</p>	 <p>Time: 2022-05-07 16:14:05 Text: Play ball in mozishan. Longitude: 123.482953 Latitude: 41.672731 Behavior: Entertainment</p>	 <p>Time: 2022-05-07 16:24:28 Text: It's a nice day outside. Longitude: 123.48299 Latitude: 41.672672 Behavior: Entertainment</p>
data4	data5	data6
 <p>Time: 2022-05-07 16:26:45 Text: Play football. Longitude: 123.483538 Latitude: 41.672707 Behavior: Entertainment</p>	 <p>Time: 2022-05-07 16:40:43 Text: Today these places are closed and statically managed. When can waves stop. Longitude: 123.482786 Latitude: 41.672053 Behavior: Tourism</p>	 <p>Time: 2022-05-07 17:22:51 Text: Mozishan play. Longitude: 123.48349 Latitude: 41.672467 Behavior: Entertainment</p>

Figure 1. Life event record diagram

图 1. 生活事件记录图

图 1 描绘了用户在公园游玩的场景，用户在这期间上传了 6 条 lifelogging，这些数据一起组成了一个连续的生活事件。本文的主要目的就是识别用户数据中单独的和连续的生活事件，并为每个事件进行分类。通过这种分类，可以帮助用户更有效的组织自己的数据，以事件为线索来管理他们的数据。

2.3. 域的概念

在本文的实验中，我们将使用数据的地理位置属性。为此，我们提出了“域”的概念，该概念基于地理坐标，将空间位置相近的 lifelogging 分类到同一区域，这一过程的示意图如图 2 所示。

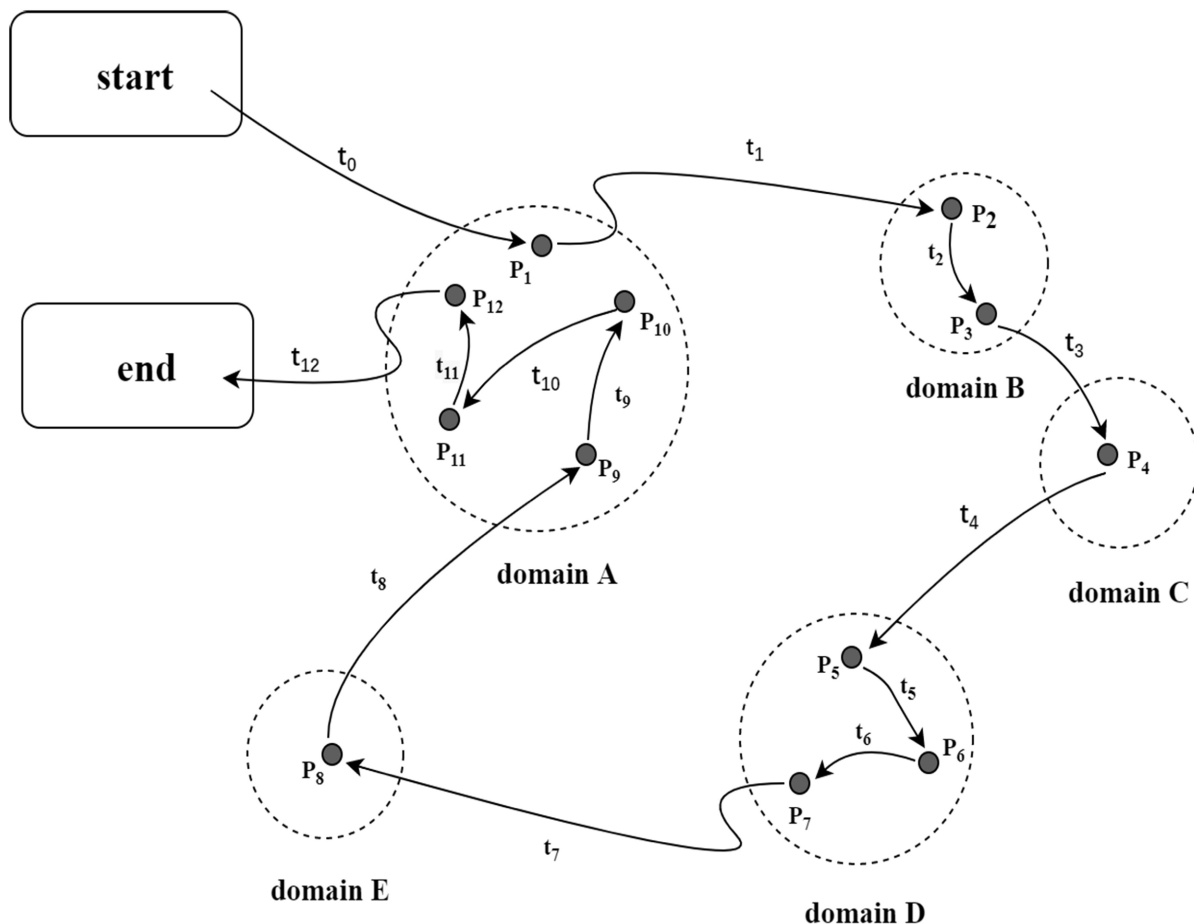


Figure 2. Domain example
图 2. 域示例图

图 2 中, 假设在某一个时间段内, 总共采集了 12 个 lifelogging 数据, 这些数据定义为 $\langle P1, \dots, P12 \rangle$, 其中 $\langle P1, P9, P10, P11, P12 \rangle$ 都是在沈阳建筑大学采集的, $\langle P2, P3 \rangle$ 是体育馆, $\langle P4 \rangle$ 是某个饭店, 我们给每一个位置分类定义为 domain, 比如 $\langle P2, P3 \rangle$ 所在的位置可以定义为 domain B。

3. 实验过程

本文提出了 LE-PDA 模型, 该模型采用了分层的方法, 分别对城市间和区域内的事件进行挖掘。在城市级别, 主要挖掘的是城市间的活动, 如出差和旅游等。在区域级别, 主要挖掘的是日常生活中的事件, 如看电影、用餐等。

3.1. 数据预处理

在实验之前, 需要对数据进行预处理, 具体步骤如下:

1、由于 GPS 定位时信号的问题会有一些噪音点和离群点。比如一些数据地点为空, 有些数据的经纬度为 0 等。所以在进行实验之前, 我们需要将这些噪音点和离群点去除。

2、数据集中存在一些冗余数据, 当用户在较短时间内连续发布多条数据时, 我们取其中一条数据作为有效数据。

经过预处理的后的 lifelogging 数量如图 3 所示:




Figure 3. Data preprocessing diagram

图3. 数据预处理图

在数据集中，我们选择了两位用户作为本次实验的对象。一位用户在12年间上传了11,032条数据，另一位用户在3年间上传了1558条数据。经过数据预处理后，我们将一些缺失数据和错误数据进行清除，保证了数据的鲁棒性和准确性。

3.2. 城市事件挖掘

挖掘城市事件时我们将城市作为域，同时需要设置起始域。文献[21]指出，人类的移动模式具有一定的规律性，通常在一段时间内会在一个或几个固定的区域中活动。在网络图中，度值越大的区域连通性越强。因此，我们选择度值较高的城市作为起始域。算法伪代码如下：

算法1：城市事件挖掘算法

Input: data, Threshold: T, F

Output: all urban event: $E = \{E_1, E_2, \dots, E_n\}$

Function detectUrbanEvents (data):

event \leftarrow list(), temp_event \leftarrow list(), E \leftarrow list(), start_domain \leftarrow list()

D \leftarrow nx.DiGraph()

degree \leftarrow dict(D.degree())

start_domain \leftarrow Constraint-based Pruning(degree)

for i **in** data **do**:

while(data[i++].city not **in** start_domain)

 add data[i] to temp_event

end while

 distance \leftarrow dtw(event, temp_event)

if(distance < F)

 add event to E

 event \leftarrow temp_event

 temp_event \leftarrow \emptyset

else

 event \leftarrow merge_function (event, temp_event)

end if

end for

return E

end

我们首先以城市为节点构建了一个网络图，并计算了各节点的度值，根据度值设定起始域。随后，我们引入了 DTW 算法，结合滑动窗口技术，来动态的计算相邻起始域之间的城市相似度。如果计算出的相似度小于设定的阈值 F ，我们将其视为两个不同的事件 `event` 和 `temp_event`，同时将 `event` 加入事件列表 `E` 中。否则，我们则认为这两个事件相等，合并为一个事件，继续循环进行比较。

3.3. 区域事件挖掘

区域事件是指起始域中的事件。在挖掘 `lifelog` 中的事件时，发现数据间的语义关系的也被认为是一个有效方案。但是如果只使用语义关系可能会使一些事件不能被准确挖掘。在图 1 所示的数据中，如果按照语义关系的方式来挖掘生活事件，那么这些数据会被认为是多个不同的事件。实际上，这是一个在公园游玩的事件。于是，我们结合语义关系和地理位置来挖掘用户数据中区域事件，过程如图 4 所示。

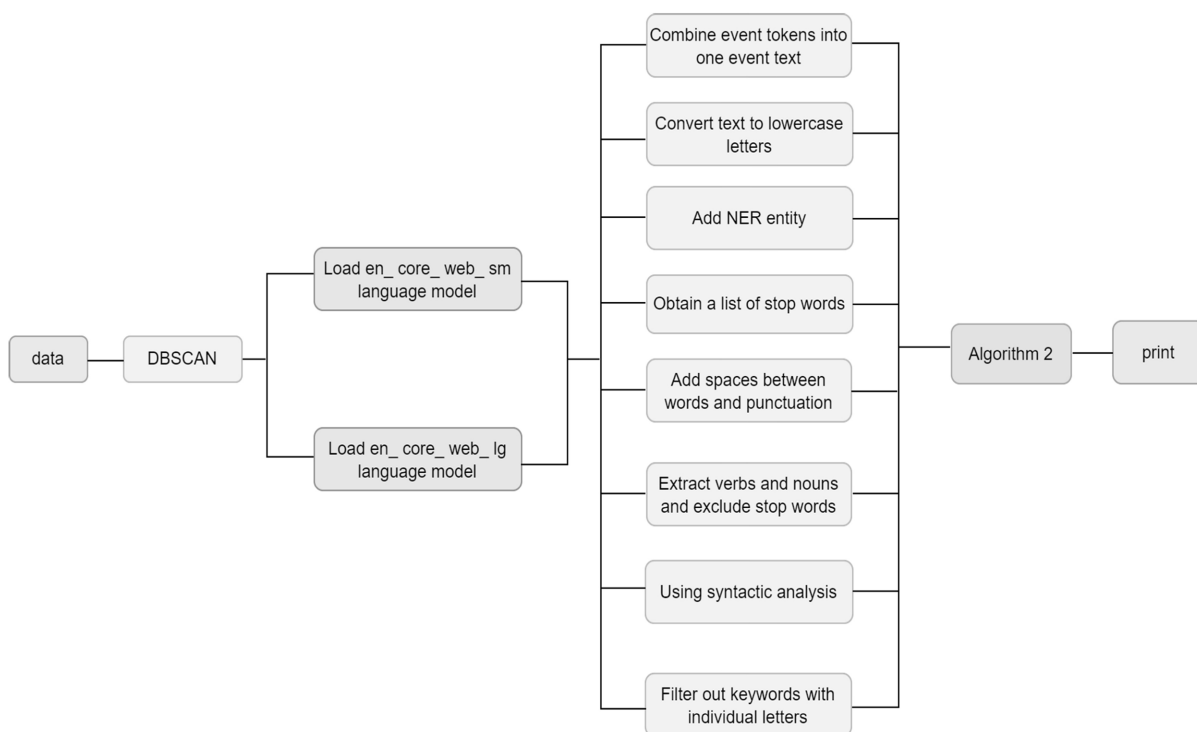


Figure 4. LE-PDA process flowchart

图 4. LE-PDA 流程图

在图 4 中，首先使用 DBSCAN 聚类算法，将数据划分为 1142 个不同的域，我们用十进制阿拉伯数字表示每一个域。接着进行文本处理，为了提高文本识别的精确度，实验使用 `en_core_web_sm` 和 `en_core_web_lg` 两种文本语言模型处理数据中的文本。然后对文本语言分别进行了停词筛选、语法识别、NER 实体识别和句法分析等方法，提取出文本中的关键词。最后经过算法 2 后得出了数据中的事件。

算法 2 的伪代码如下所示：

对于通过语言模型找到的关键词 D ，我们对每一个关键词使用 TF-IDF 进行向量化。在时间间隔小于阈值 T 的情况下，算法主要包含两个步骤：对于 TF-IDF 余弦相似度大于阈值 F 的相邻数据，或者“域”相等且余弦相似度大于 F 的不相邻数据，我们将其视为一个连续的事件 $E = \{L_1, L_2, \dots, L_n\}$ ，其中 $L_n = \{D_1, D_2, \dots, D_n\}$ 。否则我们将其视为单个的事件 $E = \{L_1, L_2, \dots, L_n\}$ ，其中 $L_n = \{D_n\}$ 。

算法 2: 区域事件挖掘算法

Input: data, Text keywords stream: D, Threshold: T, F

Output: Events data (event)

Function detectRegionalEvents (data, D):

 event \leftarrow list(), current_event \leftarrow list(), event_tokens \leftarrow list()

for i **in** data **do**:

if current_event == \emptyset

add data[i] to current_event

 add D_i to event_tokens

else

 time_interval \leftarrow data[i].time - current_event[start_time]

if (similarities (event_tomens, D_i) > F & time_interval < T)

add data[i] to current_event

 add D_i to event_tokens

else

 time_interval \leftarrow data[i+1].time - current_event[start_time]

if (similarities (event_tomens, D_{i+1}) > F & time_interval < T)

if (data[i-1].domain == data[i].domain == data[i+1].domain)

add data[i], data[i+1] to current_event

else
break
end for

add current_event to event

return event

end

4. 实验结果和分类

4.1. 实验结果和性能对比

经过模型运算之后，我们得到了两位用户的 lifelogging 中所有的事件。我们提取每一个事件的域、文本和时间特征值，得到的结果如下表 2、表 3 所示：

Table 2. User1 events

表 2. User1 事件表

序号	域	文本	时间
1	1	报告会	2011-11-05 10:23:48
2	1	实验室	2011-11-06 18:51:11
...
5214	1268	去接孩子放学……	2022-11-18 16:09:12
5215	4	陪儿子上英语……	2022-11-18 18:26:58 - 18:38:45

Table 3. User2events
表 3. User2 事件表

序号	域	文本	时间
1	1	运气是成功的……	2020-09-17 16:37:43
2	1	夜晚散步	2020-09-18 20:35:19
...
1085	1	7月5号走, 和……	2023-07-01 22:55:30
1086	50	再见啦, 老刘, ……	2023-07-05 13:40:52

在表中可以看到, User1 数据被划分为 5215 个事件, User2 数据被划分 1086 个事件。接下来, 我们对数据集中的事件进行人工标记。将本实验使用的 LE-PDA 模型和目前常用的事件挖掘 TDT 算法进行性能对比, 如图 5 所示。

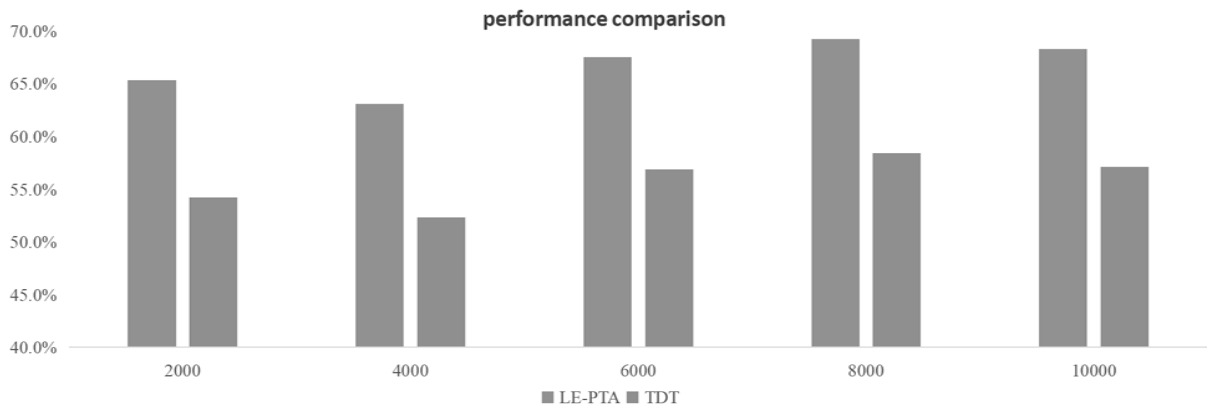


Figure 5. Performance comparison
图 5. 性能对比图

在图 5 中, LE-PDA 模型识别事件的准确率达到到了 68%, 而 TDT 算法识别事件的准确率是 56%。可以发现, 在结合了域的使用后, 本文提出的 LE-PDA 模型在性能上明显优于 TDT 算法。

4.2. 行为分类

数据集中的每一条数据都有一个行为属性。在实验结果中, 我们可以按照数据的行为属性对事件进行分类。我们首先统计事件数据中行为出现的频率。然后根据行为的频率, 可以为它们分配权重。频率最高的行为权重最高, 可以被认为是最重要的。经过分类后, 事件的类别表 4 所示:

Table 4. Behavior classification
表 4. 行为分类表

行为	User1	User2
Work in school	1157	501
Rest	938	117
On road	298	99
Meal outside	292	25
Tourism	114	7

续表

Learning	103	201
Physical exercise	94	16
Other	93	56
Meal at school	85	40
Communication	57	12
Meal at home	16	12
Work outside	1029	-
Chores	743	-
Entertainment	217	-
Party	69	-

在表中可以看到 User1 的事件被划分成了 15 个不同的类别，User2 的事件分为了 11 个类别。这个分类过程保证了每一个事件都得到了准确的分类，使得用户能够根据行为类别高效的管理事件数据。当用户想要查找某个事件时，比如在校吃饭，那么他就可以在“Meal at school”类别中来找到相应的事件。

4.3. 重要性分类

不同的事件对于用户的重要性是不一样的，当我们回想起某一年经历的事情时，首先想起的是一些重要的事情。因此，为事件添加重要性标签也是一种能够帮助用户管理数据的方法。

为此，我们采用了半监督机器学习方法来为事件自动标注重要性。我们首先随机选取了一些事件，并手动给它们标上了“不重要”、“一般”和“重要”的标签，以此作为半监督训练的基础。在此过程中，我们测试了三种不同的半监督学习模型，并记录了它们的性能表现。如下表 5 所示：

Table 5. Importance recognition performance

表 5. 重要性识别性能表

User1	precision	recall	f1-score	User2	precision	recall	f1-score
Self-training	0.59	0.62	0.56	Self-training	0.71	0.75	0.71
Co-training	0.64	0.65	0.58	Co-training	0.73	0.74	0.63
S3VM	0.73	0.71	0.69	S3VM	0.82	0.75	0.72

在上表中我们可以发现，S3VM 的性能明显优于另外两个模型，展现出较高的准确率。此外，我们还对比了在模型中加入域和行为标签前后的性能差异。结果表明，引入这些标签后，所有模型的性能均有所提升。其中，一些模型的准确率甚至提高了 20%。这一结果证明了为事件添加域和行为标签的有效性。使用 S3VM 后两位用户事件重要性分类结果如下图 6 所示。

对于 lifelogging 数据，将其划分为不同的事件进行管理不仅提升了数据的可用性，也增强了用户体验。通过为事件添加标签类别，使得管理个人数据变得既简单又直观。这种方法为用户提供了明晰的数据管理方式，让用户能够快速的对数据进行整理和归类。




Figure 6. Importance classification chart
图 6. 重要性分类图

5. 系统实现

Lifelog 一个重要的功能就是回忆，通过查看 lifelogging 数据，用户能想起许多过去珍贵的记忆。McGookin [22]用时间和地点的方式展示用户在多个区域的所拍摄的图片。文献[23]提出了基于 web 的应用程序检索 lifelogging，用户可以根据需求检索想要回忆的内容。在本节中，我们尝试以事件为核心的方式呈现用户的数据，以帮助用户更好的回忆过去。为此，我们使用 Java 和 Html 建立了一个可视化系统。以 User1 为例，展示了该用户的城市级事件。系统的主页面如图 7 所示。

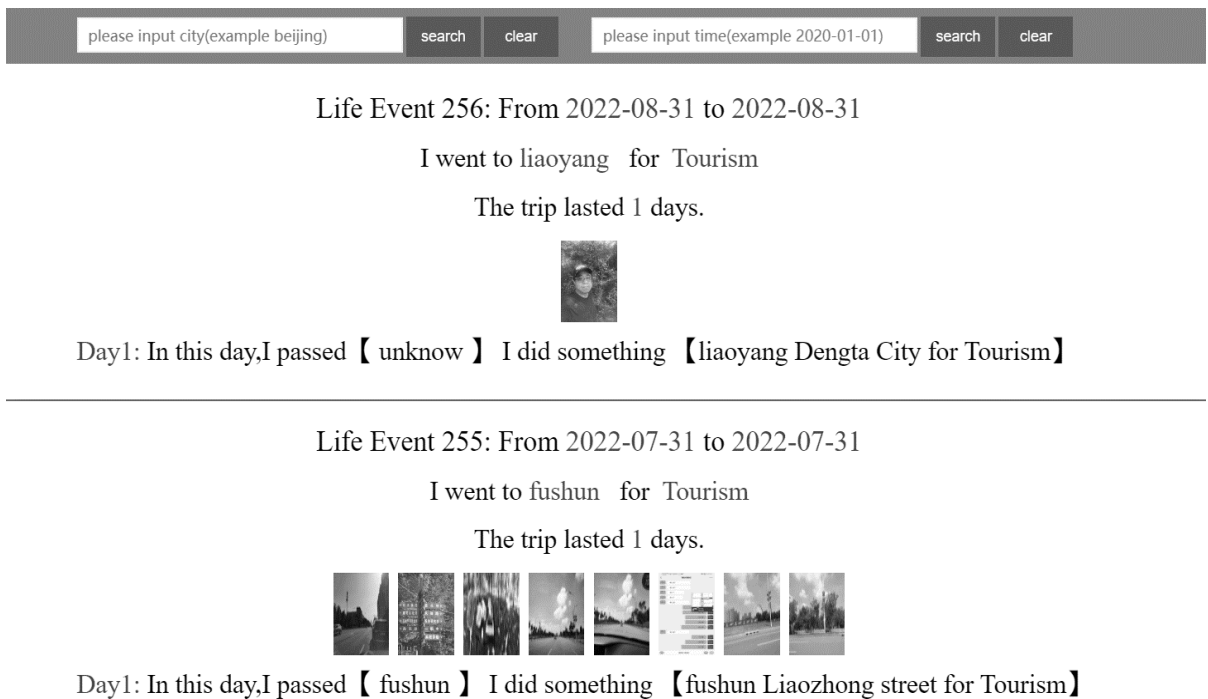


Figure 7. System display diagram
图 7. 系统展示图

在此系统中，用户可以通过搜索城市或时间查找想要回忆的内容。当搜索北京市时，系统会显示所有关于北京市所发生的事件。当搜索某一天时，系统会将包含这一天的事件进行展示。例如当我们搜索 2015 年 1 月 14 号时，显示的事件如图 8 所示。

在此图中，我们可以知道用户在 2015 年 1 月 14 号出发，前往湘潭出差。途中经过了杭州，长沙。



Figure 8. Data template diagram

图 8. 数据模板图

第二天到达湘潭。在湘潭的 Furong West Road 休息, 在 Xiaotang Road 做家务和吃饭, 在 Shuangyong South Road 工作。第三天从湘潭离开, 这次出差共持续了 3 天。

实验的结果已经公开, 读者可以在网站(<http://www.lifelog.vip/LifeEvent.html>)进行查看。通过该系统, 我们可以清晰直观的查看用户的过去的一些事情。对于数据上传者而言, 这是非常有意义的, 因为该系统可以帮助他们想起自己过去的记忆。

6. 总结与展望

在本文中, 我们介绍了一种用事件帮助用户整理 lifelogging 数据的方法, 并提出了 LE-PDA 模型。该模型通过分层挖掘将数据划分为城市级和区域级事件。同时我们对每个事件进行了分类, 用户可以通过事件标签更有效的整理数据。此外, 我们还以事件为中心建立了可视化系统, 用以帮助用户更好的回忆过去。本实验的不足之处是, 目前系统只展示了城市级事件。在未来, 我们将更新系统, 将区域级的事件也进行展示, 从而提供一个更加全面的回忆体验。

基金项目

辽宁省教育厅自然基金项目(LJKZ0595)。

参考文献

- [1] Andrew, A.H., Eustice, K. and Hickl, A. (2013) Using Location Lifelogs to Make Meaning of Food and Physical Activity Behaviors. 2013 *7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops*, Venice, 5-8 May 2013, 408-411. <https://doi.org/10.4108/icst.pervasivehealth.2013.252134>
- [2] Gurrin, C., Smeaton, A.F. and Doherty, A.R. (2014) Lifelogging: Personal Big Data. *Foundations and Trends® in Information Retrieval*, **8**, 1-125. <https://doi.org/10.1561/1500000033>
- [3] Rekimoto, J., Miyaki, T. and Ishizawa, T. (2007) LifeTag: WiFi-Based Continuous Location Logging for Life Pattern Analysis. *LoCA 2007*, Oberpfaffenhofen, 20-21 September 2007, 35-49. https://doi.org/10.1007/978-3-540-75160-1_3
- [4] Mafrur, R., Nugraha, I.G.D. and Choi, D. (2015) Modeling and Discovering Human Behavior from Smartphone Sensing Life-Log Data for Identification Purpose. *Human-Centric Computing and Information Sciences*, **5**, Article No. 31. <https://doi.org/10.1186/s13673-015-0049-7>
- [5] Ziaei, A., Sangwan, A., Kaushik, L. and Hansen, J.H. (2015) Prof-Life-Log: Analysis and Classification of Activities in Daily Audio Streams. 2015 *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, South Brisbane, 19-24 April 2015, 4719-4723. <https://doi.org/10.1109/ICASSP.2015.7178866>
- [6] Gurrin, C., Smeaton, A.F., Byrne, D., O'Hare, N., Jones, G.J. and O'Connor, N. (2008) An Examination of a Large Visual Lifelog. *Information Retrieval Technology: 4th Asia Information Retrieval Symposium, AIRS 2008*, Harbin, 15-18 January 2008, 537-542.

-
- [7] Hu, B., Song, Z. and Ester, M. (2012) User Features and Social Networks for Topic Modeling in Online Social Media. 2012 *IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, Istanbul, 26-29 August 2012, 202-209.
- [8] Liu, G.Q., Zhang, Y.J., Fu, Y.M. and Liu, Y. (2014) Behavior Identification Based on Geotagged Photo Data Set. *The Scientific World Journal*, **2014**, Article ID: 616030. <https://doi.org/10.1155/2014/616030>
- [9] Lee, R., Wakamiya, S. and Sumiya, K. (2013) Urban Area Characterization Based on Crowd Behavioral Lifelogs over Twitter. *Personal and Ubiquitous Computing*, **17**, 605-620. <https://doi.org/10.1007/s00779-012-0510-9>
- [10] Ninh, V.T., Le, T.K., Zhou, L., Piras, L., Riegler, M.A., Halvorsen, P. and Dang Nguyen, D.T. (2020) Overview of ImageCLEF Lifelog 2020: Lifelog Moment Retrieval and Sport Performance Lifelog.
- [11] Thambawita, V., Hicks, S.A., Borgli, H., et al. (2020) Pmdata: A Sports Logging Dataset. *Proceedings of the 11th ACM Multimedia Systems Conference*, Istanbul, 8-11 June 2020, 231-236. <https://doi.org/10.1145/3339825.3394926>
- [12] Lee, K.H., Urtnasan, E., Hwang, S., et al. (2022) Concept and Proof of the Lifelog Bigdata Platform for Digital Healthcare and Precision Medicine on the Cloud. *Yonsei Medical Journal*, **63**, S84. <https://doi.org/10.3349/ymj.2022.63.S84>
- [13] Yang, P., Stankevicius, D., Marozas, V., et al. (2016) Lifelogging Data Validation Model for Internet of Things Enabled Personalized Healthcare. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, **48**, 50-64. <https://doi.org/10.1109/TSMC.2016.2586075>
- [14] Cho, Y., Seo, J., Lee, H., et al. (2020) Platform Design for Lifelog-Based Smart Lighting Control. *Building and Environment*, **185**, Article ID: 107267. <https://doi.org/10.1016/j.buildenv.2020.107267>
- [15] Jalal, A. and Kamal, S. (2014) Real-Time Life Logging via a Depth Silhouette-Based Human Activity Recognition System for Smart Home Services. 2014 *11th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, Seoul, 26-29 August 2014, 74-80. <https://doi.org/10.1109/AVSS.2014.6918647>
- [16] Ribeiro, R., Trifan, A. and Neves, A.J. (2022) Lifelog Retrieval from Daily Digital Data: Narrative Review. *JMIR mHealth and uHealth*, **10**, e30517.
- [17] Rossetto, L., Inel, O., Lange, S., Ruosch, F., Wang, R. and Bernstein, A. (2023) Multi-Mode Clustering for Graph-Based Lifelog Retrieval. *Proceedings of the 6th Annual ACM Lifelog Search Challenge*, Thessaloniki, 12-15 June 2023, 36-40. <https://doi.org/10.1145/3592573.3593102>
- [18] Hwang, K.S. and Cho, S.B. (2008) Life Log Management Based on Machine Learning Technique. 2008 *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*, Seoul, 20-22 August 2008, 691-696. <https://doi.org/10.1109/MFI.2008.4648026>
- [19] Kim, M., Lee, D.W., Kim, K. and Kim, J.H. (2015) Hierarchical Structured Data Logging System for Effective Lifelog Management in Ubiquitous Environment. *Multimedia Tools and Applications*, **74**, 3561-3577. <https://doi.org/10.1007/s11042-013-1671-x>
- [20] Yen, A.Z., Huang, H.H. and Chen, H.H. (2021) Ten Questions in Lifelog Mining and Information Recall. *Proceedings of the 2021 International Conference on Multimedia Retrieval*, Taipei, 21-24 August 2021, 511-518. <https://doi.org/10.1145/3460426.3463607>
- [21] Barbosa, H., Barthelemy, M., Ghoshal, G., et al. (2018) Human Mobility: Models and Applications. *Physics Reports*, **734**, 1-74. <https://doi.org/10.1016/j.physrep.2018.01.001>
- [22] McGoekin, D. (2019) Reveal: Investigating Proactive Location-Based Reminiscing with Personal Digital Photo Repositories. *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, Glasgow, 4-9 May 2019, 1-14. <https://doi.org/10.1145/3290605.3300665>
- [23] Heller, S., Amiri Parian, M., Gasser, R., Sauter, L. and Schuldt, H. (2020) Interactive Lifelog Retrieval with Vitivr. *Proceedings of the 3rd Annual Workshop on Lifelog Search Challenge*, Dublin, 8-10 June 2020, 1-6. <https://doi.org/10.1145/3379172.3391715>