

# 基于孪生分层注意力网络模型的轨迹用户链接预测

丁鹏 王斌\* 朱苏磊

(上海师范大学信息与机电工程学院 上海 200234)

**摘要** 为进一步探究人类移动行为模式,提出一种基于孪生分层注意力的网络模型解决轨迹用户链接预测问题。该模型框架包括判别模块和检索模块,其中:判别模块对轨迹位置信息进行编码,采用改进的分层注意力网络捕获轨迹间的潜在相关性;检索模块利用判别模块计算已知用户轨迹与未知轨迹间的相似性得分,并将KNN作为分类器实现未知轨迹与用户的链接预测。在某城市的基于位置服务(LBS)的数据集上进行实验,结果表明该模型在不同用户数量中性能表现优越。

**关键词** 人类移动性 轨迹用户链接 分层注意力网络

中图分类号 TP399

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.11.030

## TRAJECTORY-USER LINK PREDICTION BASED ON SIAMESE HIERARCHICAL ATTENTION NETWORK MODEL

Ding Peng Wang Bin\* Zhu Sulei

(College of Information, Mechanical and Electrical Engineering, Shanghai Normal University, Shanghai 200234, China)

**Abstract** In order to further explore the human mobility behavior pattern, this paper proposes a network model based on Siamese hierarchical attention to solve the task of trajectory-user link prediction. The framework of model was divided into discriminant module and retrieval module, in which the discriminant module encoded the position information through trajectory embedding, and the improved hierarchical attention network was used to capture the latent correlation between trajectories. The retrieval module used the discriminant module to calculate the similarity score between the known user trajectories and the unknown trajectory. KNN was used as a classifier to link between the unknown trajectory and the user. Experiments were conducted on the dataset based on location-based service (LBS) in a city. The results show that the model in this paper performs well in different user numbers.

**Keywords** Human mobility Trajectory-user linking Hierarchical attention network

## 0 引言

当前,随着信息技术的快速发展和移动设备的普及,越来越多带有移动位置信息的轨迹数据被大量生成和记录,例如移动用户的出行数据、上网产生的手机位置更新数据、智能交通卡等不同类型的时空轨迹数据。针对轨迹数据的深度挖掘和分析有助于进一步探索个体的移动行为模式,为城市规划、兴趣点推荐、位置预测和交通预测<sup>[1-4]</sup>等领域提供有效的解决方案和建设性思考。

目前已经有许多研究人员在轨迹挖掘领域进行了广泛深入的研究,但是对于轨迹行为的相似关系挖掘,仍然有许多的不足。本文就轨迹数据挖掘中的轨迹相似性关系问题进行研究,并将其应用到轨迹用户链接任务。轨迹用户链接是许多轨迹挖掘应用中的一个重要的应用场景,它将匿名轨迹链接到生成该轨迹的用户,这是轨迹挖掘中一项新兴的研究任务,并在日常生活场景中至关重要。例如在共享骑行应用中,服务提供商通常会记录众多用户出行的时空轨迹信息,但出于隐私的保护,用户身份通常进行匿名化处理。假设后台系统中存在某些异常的轨迹信息,系统希望

重识别出这些异常的轨迹信息,从而降低潜在的风险。对于社交网络中的用户而言,通常拥有多个不同的账号来满足差异化需求,通过跨平台的信息整合,将有助于构建完整清晰的用户画像,更加全面地分析用户特征,以实现更加准确的个性化服务推荐。此外对于网络安全管理人员,有必要定期删除或者封禁发布和传播有害信息以及虚假信息的用户账号,通过对不法分子的行为模式进行分析,整合不同平台中的用户账号进行统一处理,这将大幅提升安全工作效率,有利于维护网络安全。

解决轨迹用户链接问题多采用基于序列的统计方法,主要分为两大类:基于规则的方法和基于机器学习的方法。基于规则的方法利用已知的轨迹时空信息序列,度量给定的不同轨迹之间的相似性,试图查找与已知用户最相关的轨迹。Han 等<sup>[5]</sup>利用社交媒体用户产生的地理位置数据,提出基于联合聚类的框架,在时间、空间和用户之间建立三部分同步聚类,从而完成用户身份匹配。Rossi 等<sup>[6]</sup>利用位置信息,结合用户的轨迹特征和访问特定位置的频率,建立了混合判别模型来确定两条不同轨迹间相似度,在轨迹数据相对稀疏的数据集上也能取得较好的效果。Riederer 等<sup>[7]</sup>基于地理信息数据使用时间戳计算亲密度得分,并使用加权机制度量轨迹间相似性。传统的基于规则的方法使用广泛并且容易理解,但大多方法通过计算位置的频率特征或者分布特性,难以深度挖掘轨迹序列中不同位置间的相互关系,并且当链接用户数量增多时,采用统计的方法效率低下。基于机器学习的方法首先对轨迹信息特征提取,而后对轨迹进行所属用户的判定。轨迹信息通常被视为序列信息,所以利用循环神经网络(RNN)对其建模成为主流的方法。Gao 等<sup>[4]</sup>采用深度学习方法来解用户轨迹链接问题,首先利用文本预训练模型 Word2Vec<sup>[8]</sup>将位置信息嵌入到低维空间,然后将变长轨迹输入到 RNN 中得到轨迹的表征,最后放入分类器模型完成轨迹所属用户的判别,在后续的研究中,Zhou 等<sup>[9]</sup>利用变分自编码器对 TULER 模型进行改进并提出了 TULVAE 模型框架,通过学习轨迹的层次化语义信息,进一步缓解了位置数据的稀疏性,并采用半监督学习方法提升链接能力。但上述基于学习的方法仅仅利用位置空间特征信息,未能有效利用轨迹数据中其他的丰富特征信息,例如时间特性等。

为应对上述问题带来的挑战,本文利用时间维度特征,从轨迹中获取用户移动的周期性,充分考虑了不同时段轨迹内不同位置之间以及不同轨迹之间的作用关系,建立基于孪生分层注意力的网络框架来解决轨迹用户链接问题。

## 1 数据集及问题描述

### 1.1 数据集分析

本文采用的数据集为某城市 LBS 数据,数据记录时间段为 2014 年 1 月 6 日至 17 日,每条记录包含信息的数据格式为  $(u, t, p, l_{on}, l_{at})$ ,其中:  $u$  表示用户的 ID,  $t$  表示位置信息产生的日期,  $p$  表示位置点的 ID,  $l_{on}$  和  $l_{at}$  分别表示该位置点的经纬度。为便于计算,需要将原始位置记录分为连续的轨迹,每条轨迹表示用户的一次出行信息。常用的轨迹分割策略通常按照时间阈值特性或者空间几何特性进行划分,本文使用基于时间阈值的划分方法,以天作为时间间隔对连续轨迹进行划分。根据对人类移动行为的规律性认知,通常认为人们在工作日与周末所产生的轨迹信息有差异,例如在工作日更加倾向于上下班的通勤,而在周末更可能选择商业娱乐等场所。将工作日数据与周日数据进行统一处理将增加用户数据中的噪声信息从而影响模型效果。基于此本文将滤除周末时段轨迹信息,收集到去除周末时间后的两周共 10 天用户轨迹信息。为进一步分析用户在不同时间段之间的移动规律性,对所有用户两周内出行情况进行统计分析,并建立热度图来展示不同日期对应不同时刻的轨迹出行频率。如图 1 和图 2 所示,前一周日期范围为 2014 年 1 月 6 日至 10 日,后一周时间跨度是 2014 年 1 月 13 日至 17 日,横轴代表时间,竖轴表示日期,颜色由浅到深表示用户出行次数由少到多。




图 1 前一周(1月6日至10日)出行分布热度图




图 2 后一周(1月13日至17日)出行分布热度图

可以看出,前后两周用户出行总体分布类似:在 0 点至 6 点这段时间内,用户出行次数较少,随后每个小时内的出行的频率逐渐增加;相较于夜晚,用户在白天的出行次数保持在一个相对较高的水平。此外,用户出行每天均存在两个高峰期时段,分别为早上 8 点至 11 点以及晚上 4 点至 6 点,这符合大多用户在早晚高峰出行的分布情况。对用户出行数据的处理和分析,表明用户的出行分布遵循时间周期的特性,这为后续建立分层网络模型带来了启发。

## 1.2 问题描述

轨迹数据通常包含一个区域内所采集到的大量带有时间和空间位置背景的信息,这些时空信息呈现出用户的移动行为模式,也为本文解决轨迹与用户间的匹配问题提供了数据基础。令  $T_{u_i} = \{l_{i1}, l_{i2}, \dots, l_{im}\}$  表示某一个用户  $u_i$  在一段时间间隔内所生成的轨迹,其中  $l_{ij}$  是用户  $u_i$  在某一个时间点  $t_j$  所生成的一个位置点。对于某一条轨迹  $T_k = \{l_1, l_2, \dots, l_m\}$ ,如果不能确定生成该轨迹的用户,则称之为未链接的状态。假设存在一组用户集合  $U = \{u_1, u_2, \dots, u_n\}$  以及该集合生成的一个未链接状态的轨迹集合  $\Gamma = \{T_1, T_2, \dots, T_m\}$ ,轨迹用户链接的任务就是将未链接的轨迹  $T_x$ ,  $x \in [1, m]$  与产生该轨迹的用户  $u_y$ ,  $y \in [1, n]$  完成匹配。

## 2 网络模型

在过去的研究中,轨迹用户链接问题通常被视为分类问题<sup>[4,10]</sup>,而本文从检索的角度出发,提出一种新的基于孪生分层注意力的网络模型来解决该问题。具体来说,本文模型包括判别模块和检索模块,其中判别模块采用孪生分层注意力网络并结合联合注意力机制来捕获轨迹对的潜在向量表示,进而计算出轨迹对的相似度得分;检索模块利用判别模块计算未知轨迹与已知用户轨迹信息之间的相似性得分,并结合 KNN 的分类方法来实现对于未链接轨迹的用户识别。

### 2.1 判别模块

判别模块用于度量不同轨迹之间的相似度,其基本框架为孪生网络,即由两个相同或者相似的子网络所构建,其中子网络由轨迹划分、轨迹嵌入、分层注意力网络和联合注意力机制等模块组成。判别模块结构如图 3 所示,两条轨迹 A、B 分别经过共享权值的子网络获取相应的向量表示,将提取后的特征信息进行融合并馈送至全连接层,最终得出轨迹 A、B 的相似度得分。

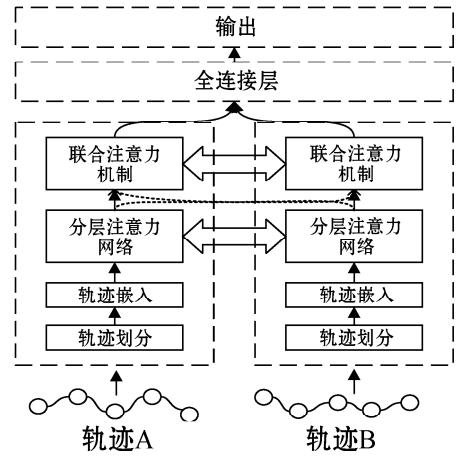


图 3 判别模块框架

#### 2.1.1 轨迹划分

通过对前文用户时空数据分析,可知用户在不同时间段往往具有不同的移动行为属性,出行分布随时段的改变也有所不同。因此,本文将用户每天产生的轨迹数据按照四个不同时段进行划分为不同的子轨迹,分别为每天的 0:00 至 8:00、8:00 至 13:00、13:00 至 19:00、19:00 至 23:00。利用轨迹信息中已有的时间特征对轨迹的分段划分,可以更加精细地捕获不同时段用户的移动行为模式。

#### 2.1.2 轨迹嵌入

由于轨迹信息维度的异质性和复杂性无法将其直接输入到模型中,所以需要对其信息进行嵌入以便进行网络模型的训练。对于输入到网络中的位置点,通常用离散的数值进行表示,例如独热编码(One-hot)。One-hot 解决了难以处理属性数据的问题,但当位置数量变得庞大时,采用这种方式进行位置编码将导致整个特征空间过大而引发维度灾难。因此本文借鉴自然语言处理中的词向量嵌入方法来学习每一个位置的嵌入表示。每个位置点可表示为  $x_i \in \mathbf{R}^d$ ,  $d$  是位置点需要嵌入的空间维度。将多个位置的嵌入信息进行拼接从而得到整条轨迹的嵌入表示  $T = \{x_1, x_2, \dots, x_n\}$ ,其中  $n$  为轨迹所包含位置的数目。在模型的训练过程中,通过不断优化每个位置的语义信息,从而得到每个位置点最优的表示向量。

#### 2.1.3 分层注意力网络

分层注意力网络<sup>[11]</sup>最先用于文本分类问题,该网络模型充分考虑了文本内具有不同层级的结构信息,包括字符、词语、短句、段落等。受此启发,本文将轨迹中的位置编码视作文本信息,即整条轨迹可以划分为多条子轨迹,每个子轨迹又由多个位置点组成,将位置点所组成的结构化信息输入到分层注意力网络中进行轨迹特征的提取,捕获位置与轨迹间多级联相关性。

本文采用的分层注意力网络结构如图 4 所示,包

括位置建模和子轨迹建模。具体而言,对不同时段划分后的子轨迹进行嵌入,可获得多条子轨迹嵌入信息。接着进行位置编码与注意力权值计算,完成位置建模。随后,将位置建模的输出信息传送至子轨迹建模网络中进行子轨迹编码,最终得到整天轨迹信息的表征。分层注意力网络由双向门控循环单元(Bi-GRU)模块和注意力机制模块组成,Bi-GRU 相比于单向的 GRU 网络,可以利用额外的后向层学习过去位置和未来位置的轨迹信息。此外 Bi-GRU 相比于双向长短期记忆网络(Bi-LSTM)参数更少,且更容易收敛。

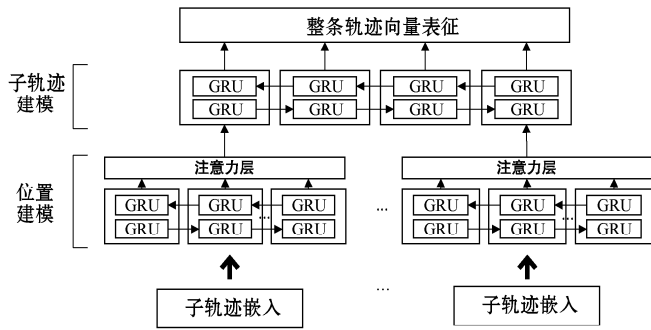


图4 分层注意力网络结构框架

假设某个用户某一天的轨迹由  $L$  条子轨迹  $s_i$  组成,  $i \in [1, L]$ , 根据 2.1.1 节轨迹划分时段, 本文  $L$  取 4, 每条子轨迹中包含  $T_i$  个位置  $l_{it}$ ,  $t \in [1, T_i]$ , 令  $x_{it}$  表示第  $i$  条子轨迹中第  $t$  个位置的嵌入向量, 通过 Bi-GRU 编码得到子轨迹中的向量表示  $h_{it}$ , 编码过程如下:

$$\vec{h}_{it} = \overrightarrow{GRU}(x_{it}) \quad t \in [1, T_i] \quad (1)$$

$$\overleftarrow{h}_{it} = \overleftarrow{GRU}(x_{it}) \quad t \in [T_i, 1] \quad (2)$$

$$h_{it} = [\vec{h}_{it}, \overleftarrow{h}_{it}] \quad (3)$$

为了衡量不同位置在子轨迹中的重要程度, 利用注意力机制为不同位置分配权值, 计算位置向量表示  $h_{it}$  与上下文向量的  $u_i$  的相关性来获取不同位置的注意力得分。其中上下文向量  $u_i$  表示位置级别的潜在向量, 包含了子轨迹中的所有上下文信息, 在位置建模注意力层中充当查询向量的作用, 并且在训练过程中  $u_i$  通常随机初始化并随其他参数共同学习。接着利用 SoftMax 函数归一化得到相应的权值  $\alpha_{it}$ , 最后计算加权和并作为子轨迹的表示  $s_i$ :

$$u_{it} = \tanh(W_l h_{it} + b_l) \quad (4)$$

$$\alpha_{it} = \frac{\exp(u_{it}^T u_i)}{\sum_t \exp(u_{it}^T u_i)} \quad (5)$$

$$s_i = \sum_t \alpha_{it} h_{it} \quad (6)$$

式中:  $W_l, b_l$  为位置建模注意力层中训练所需要的学习参数。

给定子轨迹表示向量  $s_i$ , 以类似的方式使用 Bi-

GRU 编码子轨迹向量获得整条轨迹的表示向量  $h_i$ , 编码过程如下:

$$\vec{h}_i = \overrightarrow{GRU}(s_i) \quad t \in [1, L] \quad (7)$$

$$\overleftarrow{h}_i = \overleftarrow{GRU}(s_i) \quad t \in [L, 1] \quad (8)$$

$$h_i = [\vec{h}_i, \overleftarrow{h}_i] \quad (9)$$

时空轨迹中的复杂性在于不同部分的相互作用, 不同位置间能够相互影响, 同时也影响由位置组成的子轨迹。分层注意力网络经过 Bi-GRU 与注意力层的协同运作, 构建出从位置级别建模到子轨迹级别建模再到整条轨迹的多层级联结结构, 能更好地理解轨迹中的语义并提取丰富的特征信息。

#### 2.1.4 联合注意力机制

在大量的研究中 RNN 被用于获取轨迹表征, 并通常结合注意力机制来学习不同位置对于整条轨迹的重要性<sup>[12]</sup>。值得注意的是, 本文以孪生网络作为基本框架, 除了考虑单条轨迹内不同位置的权重信息, 同时还需关注轨迹对之间的共同信息, 为此本文引入联合注意力机制<sup>[13]</sup>, 在经过分层注意力网络编码后, 联合注意力机制通过交换不同轨迹之间的查询向量完成注意力得分的计算。具体而言, 经过分层注意力编码后轨迹 A 的特征向量表示为  $\{h_1^A, h_2^A, \dots, h_m^A\}$ , 轨迹 B 的特征向量表示为  $\{h_1^B, h_2^B, \dots, h_n^B\}$ , 在对轨迹 A 进行子轨迹建模注意力计算时, 将轨迹 B 中的特征向量作为轨迹 A 的查询向量, 即  $q^A = \{h_1^B, h_2^B, \dots, h_n^B\}$ , 同样对轨迹 B 进行子轨迹建模注意力得分计算时, 将轨迹 A 中的特征向量作为轨迹 B 的查询向量, 即  $q^B = \{h_1^A, h_2^A, \dots, h_m^A\}$ 。据此, 不同轨迹对应的查询向量与轨迹的特征向量进行点积操作计算相似度, 并利用 SoftMax 函数将权重归一化, 最后将权重与原始轨迹的特征向量加权求和得到最终轨迹的向量表示, 轨迹 A 和轨迹 B 的联合注意力得分计算如下:

$$f(q, h) = h^T q \quad (10)$$

$$a_i^A = \frac{\exp(f(q^A, h_i^A))}{\sum_m \exp(f(q^A, h_m^A))} \quad (11)$$

$$a_j^B = \frac{\exp(f(q^B, h_j^B))}{\sum_n \exp(f(q^B, h_n^B))} \quad (12)$$

$$y^A = \sum_m a_i^A h_i^A \quad (13)$$

$$y^B = \sum_n a_j^B h_j^B \quad (14)$$

式中:  $f$  表示点积计算函数;  $a_i^A$  和  $a_j^B$  分别表示轨迹 A 和 B 的注意力权重分布;  $y^A$  和  $y^B$  分别表示轨迹 A 和 B 的最终的特征表示向量。

联合注意力机制中采用的交叉注意力得分计算方

式让模型更加关注轨迹对之间的公共关键信息,减少了轨迹信息中潜在的噪声影响,有效地提升模型的链接性能。在得到轨迹 A 和 B 的特征向量  $y^A$ 、 $y^B$  后对其进行拼接,经过多层前馈网络计算轨迹对的相似度,最终相似度得分经由 Sigmoid 函数转化为输出结果,损失函数为交叉熵:

$$L = - \sum_{i=1}^n y'_i \log y_i + (1 - y'_i) \log(1 - y_i) \quad (15)$$

式中: $y_i$ 和  $y'_i$ 分别表示预测值和目标值。

## 2.2 检索模块

用户与其出行的位置之间通常存在一定的相关性。例如老师的出行地点更倾向于学校,而医生的出行位置则更倾向于医院,大多数用户由于工作或者学习的因素,在移动行为中会遵循潜在的出行模式,换句话说,人们更喜欢访问在过去所经过的位置。本文中获得的轨迹信息分为训练集和测试集,已知训练集中的所有信息,包括用户 ID 以及用户所生成的轨迹信息,利用这些已知的信息,建立一个用户与位置点的相关信息表,即不同的用户在一段时间内会经过多个位置点,反之某一个位置点也映射多个不同的用户信息。

建立用户与位置的相关信息表,为完成未知轨迹与用户的匹配奠定了基础。首先未知轨迹中的位置信息可以通过相关信息表进行查询筛选,得到一组候选用户的集合,本文认为未知的轨迹将归属于候选用户集合中的某一个用户;接着将已知候选用户及其轨迹信息与未知的轨迹信息组成轨迹对送入判别模块中,判断其相似性得分;最后采用基于 KNN 的分类方法对轨迹信息所属用户得分进行投票,并对候选用户按照相似性得分进行排序以获得有效的候选匹配用户身份信息。得分最高的用户即为该未知轨迹的归属用户,通过上述检索方式,最终可以完成未链接的轨迹与用户间的匹配。

## 3 实验与结果分析

### 3.1 数据集构造

由 1.1 节可知本文实验数据为包含去除周末的两周轨迹数据,将前一周的数据作为训练数据用于网络模型中轨迹对的判别,后一周的数据为测试集用于轨迹的检索。本文中判别网络模块基于孪生网络构建,而孪生网络通常由两个相同的子网络组成,因此需要构建合理的数据集来放入模型进行训练。构造正负样本对是构建孪生网络数据集常用的方法,本文的样本训练结构以元组的形式输入,例如,元组可表示成:

(轨迹 A, 轨迹 B, 标签)。如果标签为 1,则认为轨迹 A 和轨迹 B 来自同一用户,称之为正样本;如果标签是 0,则认为轨迹 A 和轨迹 B 来自不同的用户并称之为负样本。为了保证数据集中正负样本之间的数据平衡,将采样正负样本的比例设为 1:1。需要注意的是,在构建训练数据时仅用到的是前一周的数据并不涉及后一周的数据。将构建好的正负样本数据集打乱顺序后,取 80% 的数据作为训练集,20% 的数据作为测试集。

### 3.2 实验信息

#### 3.2.1 实验参数和性能指标

本文中模型的参数设置如表 1 所示。

表 1 参数设置

参数	模型使用的参数或方法
迭代次数	100
学习率	0.01
位置编码嵌入维度	250
Bi-GRU 隐层维度	300
优化器	Adam

本文采用两种常用的评价指标来验证轨迹与用户之间的链接效果,ACC@K 和 Macro-F1。ACC@K 用来评估用户与轨迹之间链接预测的准确率,其计算式如下:

$$A_{CC@K} = \frac{\text{预测正确的轨迹数}@K}{\text{所有的轨迹数量}} \quad (16)$$

式中: $K$  表示一个变量,通常取正整数,表示所选用户在候选用户集合中的一个排名。本文分别取  $K$  为 1、5 和 10 作为准确率评价度量。

Macro-F1 表示精确率( $M_{acro-P}$ )以及召回率( $M_{acro-R}$ )的调和平均,其计算方式如下:

$$M_{acro-F1} = \frac{2 \times M_{acro-P} \times M_{acro-R}}{M_{acro-P} + M_{acro-R}} \quad (17)$$

本文实验环境为 Ubuntu 18.04 LTS 系统,选用 Python 作为编程语言,采用 Pytorch 深度学习开源框架,CPU 为 Intel Xeon Gold 6226R,GPU 为 RTX3090。

#### 3.2.2 实验对比方法

在现有的研究中,解决用户轨迹链接的问题方法分为基于规则的以及基于机器学习的方法,为了评估实验效果,本文分别选用以下方法进行对比验证:

(1) MSQ:一种基于规则的方法。Ma 等<sup>[14]</sup>利用最大似然估计的方法来识别用户,即通过最小化匹配轨迹之间的期望平方来匹配不同的轨迹。

(2) WYCI:一种基于规则的方法。Rossi 等<sup>[6]</sup>提出了一种用户概率识别算法,该算法利用用户在不同

位置登录活动的频率来近似位置访问的概率。通过计算用户运动轨迹的概率,可以用来识别未链接的轨迹是否属于用户。

(3) TULER:一种基于深度学习的方法。Gao 等<sup>[4]</sup>最早提出深度学习来解决 TUL 问题。他们首先通过 Word2Vec 将签到轨迹信息嵌入到低维向量中,然后通过改进的循环神经网络(LSTM、GRU 等)对其进行编码,最后通过分类器识别出轨迹所属的用户。

(4) TULVAE:一种基于深度学习的方法。Zhou 等<sup>[9]</sup>进一步改进了 TULER 网络,使用可变自编码器通过 RNN 隐层状态学习随机潜在轨迹语义,并使用半监督学习方法提高用户轨迹链接能力。

### 3.3 实验结果

本文分别选取 400 名以及 800 名用户的轨迹数据进行实验,结果如表 2 和表 3 所示,可以看出本文模型在各个评价指标方面均取得了最佳效果。例如在 400 名用户数量中,与 MSQ、WYCI、TULER 和 TULVAE 相比,本文模型在 ACC@1 指标上分别提升了 6.04 百分点、5.20 百分点、16.87 百分点和 6.92 百分点,类似地在 800 名用户数量中本文模型在 ACC@1 指标上分别提升了 3.63 百分点、3.05 百分点、17.79 百分点和 4.70 百分点。

表 2 400 名用户中不同方法的性能比较(%)

对比方法	ACC@1	ACC@5	ACC@10	Macro-F1
MSQ	88.96	92.57	93.25	88.76
WYCI	89.80	92.10	92.46	90.82
TULER	78.13	81.58	83.36	76.84
TULVAE	88.08	91.73	92.84	86.68
本文模型	95.00	98.50	99.25	93.42

表 3 800 名用户中不同方法的性能比较(%)

对比方法	ACC@1	ACC@5	ACC@10	Macro-F1
MSQ	86.62	92.66	93.36	86.13
WYCI	87.20	91.19	91.59	88.19
TULER	72.46	78.10	79.44	71.44
TULVAE	85.55	90.31	91.81	84.32
本文模型	90.25	98.50	98.97	87.59

其中 MSQ 和 WYCI 采用基于统计规则的方法来实现轨迹间的相似度判别,但它们无法捕获轨迹中前后位置的相关性,具有一定的局限性,在基于学习的方法中可以看出 TULER 模型效果较差,这是由于该模型没有深度挖掘出轨迹中的潜在特征,并且忽略了轨迹中不同位置间的重要性,导致匹配的准确率较低,而


TULVAE 通过大量未标记的数据进行半监督学习,用高维潜在变量表示轨迹的层次和结构语义,相比 TULER 提升了链接的性能,但是该模型仅通过变分自编码器形成固定的先验分布,容易忽略时空数据中潜在的分布信息,并且该模型尚未考虑时间维度信息,性能还有待进一步提高。本文通过数据分析挖掘出用户在不同时段具有不同行为模式,提出基于孪生分层注意力网络模型学习轨迹内与轨迹间的语义信息,并引入联合注意力机制聚焦轨迹中的共同信息部分。本文模型的优势在于有效地捕获不同轨迹间的相似性关系,同时采用基于规则的检索方法使得模型更加准确地识别未链接轨迹的所属用户。

图 5 和图 6 形象展示了 23 号和 14 号用户的若干轨迹和不同模型对应的预测情况,观察发现图 5(a) 中轨迹 1 和轨迹 4 以及图 6(a) 中轨迹 1 和轨迹 2 中位置序列连续密集,除 TULER 链接效果不稳定外,其他模型均成功链接轨迹到相应的用户。然而在位置序列极其稀疏的轨迹中,通常只包含一个或两个位置点,例如图 5(a) 中的轨迹 2 和轨迹 3 以及图 6(a) 中的轨迹 3 和轨迹 4,其他模型难以有效提取轨迹内的特征信息从而对用户的类别进行判定。本文模型通过相关信息表查询得出候选用户,不直接处理轨迹进行分类,即使在只包含单个位置点的轨迹中也能检索到潜在的所属用户,例如图 6(a) 中轨迹 4。



(a) 23 号用户若干轨迹视图 (b) 不同模型轨迹预测情况

图 5 23 号用户轨迹预测示例




(a) 14 号用户若干轨迹视图 (b) 不同模型轨迹预测情况

图 6 14 号用户轨迹预测示例

本文检索模块通过建立用户与位置相关信息表筛选候选用户,相比直接与训练集中所有用户轨迹进行对比,本文所提检索方式更具有优势。图 7 中各子图分别展示了 400 用户和 800 用户中不同检索方式的平均检索消耗时间以及准确率 ACC@1 对比情况,从图 7(a) 中可看出本文模型检索消耗的时间远远小于直接检索的方式,利用相关信息表对训练集中所有用户进

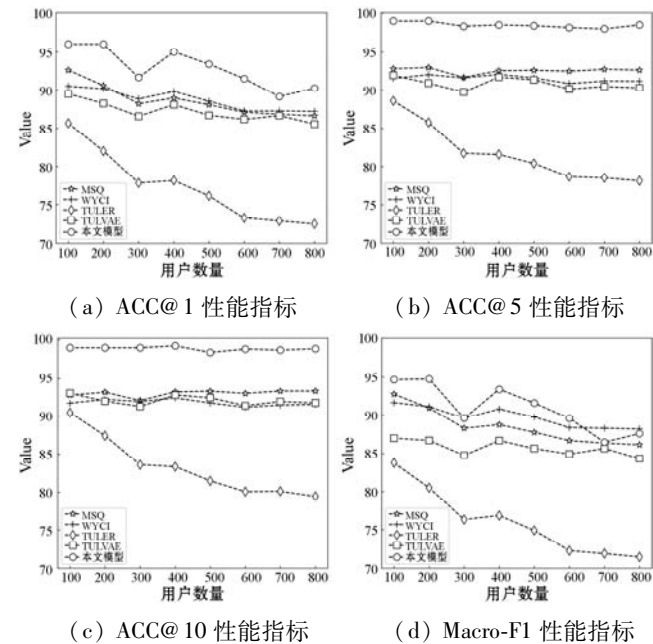
行初步筛选,匹配得出最大概率候选用户集合,进一步减少了检索的计算量与时间。另外,从图 7(b)中观察到采用直接检索方式准确率 ACC@1 低于本文检索方法,直接检索时将未知轨迹与训练集中所有用户轨迹进行相似度判别,存在其他用户轨迹与未知轨迹相似度得分近似但地理空间中无关联的情景,增大轨迹与用户匹配的难度,降低了预测准确率。



(a) 对比检索时间 (b) 对比检索准确率

图 7 检索模块性能分析

为避免数据采样不均以及数据中存在噪声所造成的实验误差,本文进一步探究不同用户数量下各个模型的性能表现,结果如图 8 所示。



(a) ACC@1 性能指标 (b) ACC@5 性能指标  
(c) ACC@10 性能指标 (d) Macro-F1 性能指标

图 8 不同用户数量不同评价指标变化

可以看出本文模型在不同用户数量下以及不同评价指标下的性能表现出色,在 ACC@K 的性能指标中均优于其他方法,但在多分类任务评价指标 Macro-F1 下本文模型效果表现不稳定,例如,在图 8(d)中本文模型在 700 用户数量时略差于 WYCI 方法,导致该情况出现的原因如下:(1) 为优化模型以及增加训练的速度,本文对输入到网络中的轨迹长度进行限定,超过预设长度的轨迹信息被舍弃,在一定程度上造成某些轨迹中的位置点丢失,导致轨迹中特征提取不充分。(2) 随着训练数据中用户数量的增加,在模型检索过

程中筛选出的候选用户数量同样有所增加,在后续的用户轨迹提取及相似度判别部分给本文模型带来了难度和负担,影响了模型的效果。

另外,从图 8 中观察到,当用户数量增长时,网络模型的评价效果总体呈现下降的趋势,但在 300 用户数量下模型效果会产生浮动,这是由于 300 至 400 名用户内轨迹数据相对密集,位置信息被充分挖掘,所以在这一用户数量区间内轨迹与用户间的链接效果较好,同时这也表明了在不同用户数量下进行性能对比的必要性。

### 4 结 语

针对轨迹与用户链接问题,本文提出一个全新的基于分层注意力网络框架来解决用户轨迹预测链接问题。整个框架包括判别模块和检索模块,其中判别模块通过分层注意力网络提取轨迹特征,并引入联合注意力机制来增强轨迹对相似性判别性能;检索模块利用用户与位置的相关性信息,筛选出候选用户并利用判别模块实现了未链接轨迹的判别。本文的框架结合基于规则检索和基于机器学习方法的优点,提出了更加通用和合理的链接预测方法。在复杂的 LBS 数据集中通过实验分析验证了本文模型的优势,在后续的工作中将继续探索优化检索过程,从而进一步提高链接的效率和性能。

### 参 考 文 献

[ 1 ] Korah P I, Cobbinah P B, Nunbogu A M, et al. Spatial plans and urban development trajectory in Kumasi, Ghana [ J ]. *GeoJournal*, 2017, 82(6) : 1113 - 1134.

[ 2 ] Ye M, Yin P, Lee W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation [ C ] // 34th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2011 : 325 - 334.

[ 3 ] Althché F, Fortelle A L. An LSTM network for highway trajectory prediction [ C ] // 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), 2017 : 353 - 359.

[ 4 ] Gao Q, Zhou F, Zhang K, et al. Identifying human mobility via trajectory embeddings [ C ] // 26th International Joint Conference on Artificial Intelligence, 2017 : 1689 - 1695.

[ 5 ] Han X, Wang L, Xu L, et al. Social media account linkage using user-generated geo-location data [ C ] // 2016 IEEE Conference on Intelligence and Security Informatics (ISI), 2016 : 157 - 162.



- 侵检测模型[J]. 计算机应用,2021,41(5):1372-1377.
- [16] 张松,李江涛,别东洋,等. 一种基于单通道 sEMG 分解与 LSTM 神经网络相结合的手势识别方法[J]. 仪器仪表学报,2021,42(4):228-235.
- [17] 张兰霞,胡文心. 基于双向 GRU 神经网络和双层注意力机制的中文文本任务关系抽取研究[J]. 计算机应用与软件,2018,35(11):130-135,189.
- [18] 燕婷,王于超,金中一. 基于 CNN 与 GRU 降噪自编码的心电信号分类方法[J]. 软件导刊,2020,19(4):75-78.
- [19] 丁娜娜,张龙波,吴志勇. 基于 CNN 和 BiGRU-Attention 模型的心律异常判别研究[J]. 网络安全技术与应用,2021(2):12-18.
- [20] Luong M T, Pham H, Manning C D. Effective approaches to attention-based neural machine translation[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. ACL,2015.
- [21] Kyunghyun C, Yoshua B. Neural machine translation by jointly learning to align and translate[EB]. arXiv:1508.04025,2016.
- [22] Yin W P, Schutze H, Xiang B, et al. ABCNN: Attention-based convolutional neural network for modeling sentences pairs[EB]. arXiv:1512.05193,2018.
- [23] 马利,刘新宇,李皓宇,等. 应用空洞卷积的神经网络轻量化方法[J]. 计算机工程与应用,2022,58(5):85-93.
- [24] Khushaba R, Kodagoda S, Takruri M, et al. Toward improved control of prosthetic fingers using surface electromyogram(EMG) signals[J]. Expert Systems with Applications, 2012,39:10731-10738.
- [25] Cao F L, Guo W H. Deep hybrid dilated residual networks for hyperspectral image classification[J]. Neurocomputing, 2020,384:170-181.
- [26] Li C M, Qiu Z L, Cao X Y, et al. Hybrid dilated convolution with multi-scale residual fusion network for hyperspectral image classification[J]. Micromachines,2021,12(5):545.
- [27] 程广涛,巩家昌,赵洪伟. 基于膨胀卷积和稠密连接的烟雾识别办法[J]. 计算机工程,2020,46(4):253-259.
- [28] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB]. arXiv:1511.07122,2016.
- [29] Al-Hadeethi H, Abdulla S, Diykh M, et al. Adaptive boost LS-SVM classification approach for time-series signal classification in epileptic seizure diagnosis applications[J]. Expert Systems with Applications,2020,161:113676.
- [30] 杭成成. 基于 sEMG 信号的下肢运动意图识别研究[D]. 武汉:武汉理工大学,2019.
- [9] Hamidi-Sepehr F, Kwak Y, Chatterjee D. 5G NR PDCCH: Design and performance[C]//IEEE 5G World Forum,2018:250-255.
- [10] Kim T Y, Kim Y S. Dynamic PDCCH adaptation based on DMRS detection for UE power saving in 5G new radio[C]//90th Vehicular Technology Conference,2019:1-2.
- [11] Braun V, Schober K, Tirola E. 5G NR physical downlink control channel: Design, performance and enhancements[C]//IEEE Wireless Communications and Networking Conference,2019:1-6.
- [12] 李琳潇. LTE-A 空口监测分析仪小区搜索的研究与实现[D]. 重庆:重庆邮电大学,2019.
- [13] Jalali A, Ding Z. Joint detection and decoding of polar coded 5G control channels[J]. IEEE Transactions on Wireless Communications,2020,19(3):2066-2078.

---

(上接第 219 页)

- [6] Rossi L, Musolesi M. It's the way you check-in: Identifying users in location-based social networks[C]//2nd ACM Conference on Online Social Networks,2014:215-226.
- [7] Riederer C, Kim Y, Chaintreau A, et al. Linking users across domains with location data: Theory and validation[C]//25th International Conference on World Wide Web, 2016:707-719.
- [8] Mikolov T, Sutskever I, Chen K, et al. Distributed representations of words and phrases and their compositionality[EB]. arXiv:1310.4546,2013.
- [9] Zhou F, Gao Q, Trajcevski G, et al. Trajectory-User linking via variational autoencoder[C]//27th International Joint Conference on Artificial Intelligence,2018:3212-3218.
- [10] Luo X, Li S, Peng Y. CNNTOP: A CNN-based trajectory owner prediction method[EB]. arXiv:2001.01185,2020.
- [11] Yang Z, Yang D, Dyer C, et al. Hierarchical attention networks for document classification[C]//2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2016:1480-1489.
- [12] Miao C, Wang J, Yu H, et al. Trajectory-User linking with attentive recurrent network[C]//19th International Conference on Autonomous Agents and MultiAgent Systems,2020:878-886.
- [13] Feng J, Zhang M, Wang H, et al. Dplink: User identity linkage via deep neural network from heterogeneous mobility data[C]//The World Wide Web Conference,2019:459-469.
- [14] Ma C Y T, Yau D K Y, Yip N K, et al. Privacy vulnerability of published anonymous mobility traces[C]//16th Annual International Conference on Mobile Computing and Networking,2010:185-196.

---

(上接第 192 页)

- [8] 张德民,曾艳辉,张洋. 5G 中基于功率测量的 PDCCH 自适应盲检测算法[J]. 计算机应用与软件,2020,37(3):117-122.