

融合全局和局部特征的下一个兴趣点推荐方法*

石美惠, 申德荣, 寇月, 聂铁铮, 于戈

(东北大学 计算机科学与工程学院, 辽宁 沈阳 110169)

通信作者: 申德荣, E-mail: shenderong@cse.neu.edu.cn



摘要: 随着海量移动数据的积累, 下一个兴趣点推荐已成为基于位置的社交网络中的一项重要任务. 目前, 主流方法倾向于从用户近期的签到序列中捕捉局部动态偏好, 但忽略了历史移动数据蕴含的全局静态信息, 从而阻碍了对用户偏好的进一步挖掘, 影响了推荐的准确性. 为此, 提出一种基于全局和局部特征融合的下一个兴趣点推荐方法. 该方法利用签到序列中的顺序依赖和全局静态信息中用户与兴趣点之间、连续签到之间隐藏的关联关系建模用户移动行为. 首先, 引入两类全局静态信息, 即 User-POI 关联路径和 POI-POI 关联路径, 学习用户的全局静态偏好和连续签到之间的全局依赖关系. 具体地, 利用交互数据以及地理信息构建异构信息网络, 设计关联关系表示学习方法, 利用相关度引导的路径采样策略以及层级注意力机制获取全局静态特征. 然后, 基于两类全局静态特征更新签到序列中的兴趣点表示, 并采用位置与时间间隔感知的自注意力机制来捕捉用户签到序列中签到之间的局部顺序依赖, 进而评估用户访问兴趣点概率, 实现下一个兴趣点推荐. 最后, 在两个真实数据集上进行了实验比较与分析, 验证了所提方法能够有效提升下一个兴趣点推荐的准确性. 此外, 案例分析表明, 建模显式路径有助于提供可解释的推荐结果.

关键词: 兴趣点推荐; 注意力机制; 顺序依赖; 用户偏好; 可解释

中图法分类号: TP311

中文引用格式: 石美惠, 申德荣, 寇月, 聂铁铮, 于戈. 融合全局和局部特征的下一个兴趣点推荐方法. 软件学报, 2023, 34(2): 786-801. <http://www.jos.org.cn/1000-9825/6712.htm>

英文引用格式: Shi MH, Shen DR, Kou Y, Nie TZ, Yu G. Next Point-of-interest Recommendation Approach with Global and Local Feature Fusion. Ruan Jian Xue Bao/Journal of Software, 2023, 34(2): 786-801 (in Chinese). <http://www.jos.org.cn/1000-9825/6712.htm>

Next Point-of-interest Recommendation Approach with Global and Local Feature Fusion

SHI Mei-Hui, SHEN De-Rong, KOU Yue, NIE Tie-Zheng, YU Ge

(School of Computer Science and Engineering, Northeastern University, Shenyang 110169, China)

Abstract: As considerable amounts of mobility data have been accumulated, next point-of-interest (POI) recommendation has become one of the important tasks in location-based social networks. Existing approaches for next POI recommendation mainly focus on capturing local dynamic preferences from user's recent check-in records, but ignore global static information in historical mobility data. As a result, it prevents further mining of user's preferences and limits the recommendation accuracy. To this end, a global and local feature fusion based approach is proposed for next POI recommendation (GLNR). GLNR can model user dynamic behavior by taking advantage of the sequential dependencies between check-ins and the underlying relationships between entities contained in global static information. Two types of global static information are firstly introduced, i.e., user-POI association paths and POI-POI association paths, to learn user's global static preferences and the global dependency between successive check-ins. Specifically, a heterogeneous information network is constructed based on interactive data and geographical information. To capture global static features, a relevance-guided path sampling strategy and a hierarchical attention based representation learning method are designed. Moreover, the representations of POIs in the user's check-in sequence are updated based on the two types of global static features. Position and time interval aware self-attention

* 基金项目: 国家自然科学基金(62172082, 62072084, 62072086, U1811261); 基本科研业务费(N2116008)

收稿时间: 2022-01-10; 修改时间: 2022-04-01; 采用时间: 2022-05-17; jos 在线出版时间: 2022-07-22

mechanism are further utilized to model the sequential dependency between multiple check-ins. Then, the check-in probability is predicted and a set of next POIs is recommended for the target user. Finally, the extensive experiments are conducted on two real-world datasets to evaluate the performance of the proposed model GLNR. Experimental results validate the superiority of GLNR for improving recommendation accuracy. Besides, the case study indicates that the explicit paths in the global static information help GLNR to provide interpretable recommendations.

Key words: point-of-interest recommendation; attention mechanism; sequential dependency; user preferences; interpretable

随着智能移动设备的普及, 基于位置的社交网络(location-based social networks, LBSNs)受到广泛关注, 如 Foursquare、Gowalla 等. LBSNs 将网络空间与物理世界联系在一起, 用户可以访问兴趣点(point-of-interest, POI), 如餐厅、商场和博物馆等, 同时通过发布兴趣点签到来分享生活经历. LBSNs 产生的海量移动数据可用于用户建模和个性化服务, 进而催生了学术界对兴趣点推荐的研究. 为用户推荐感兴趣的位置不仅可以改善用户体验、提高平台服务质量, 而且还能促进商户进行有针对性的广告宣传, 提升商户效益.

针对传统的兴趣点推荐任务, 典型的方法是利用协同过滤挖掘用户偏好^[1-7]. 协同过滤方法能够捕捉用户和兴趣点交互的关联特征, 因此可以有效地实现兴趣点推荐. 但通常将用户视为一个静态实体, 其偏好是固定的, 忽略了用户偏好的衰减和偏移. 根据已有的分析可知, 用户的移动行为存在较强的顺序依赖关系^[8], 如图 1 所示, 用户 A 在访问商场、咖啡厅和电影院后又去了川菜馆就餐. 用户的顺序行为有助于揭示用户偏好的演变, 因此, 研究者们进一步提出下一个兴趣点推荐问题, 探索了用户签到之间的顺序依赖对用户访问兴趣点的影响. 现有的大部分下一个兴趣点推荐工作主要是采用深度学习技术挖掘用户移动行为中的偏好特征^[9-18]. 基于深度学习的方法虽然一定程度上提升了推荐的准确性, 但仅依靠局部动态信息, 即近期签到的顺序, 难以全面地建模用户行为, 在捕捉复杂的用户偏好时表示能力有限.

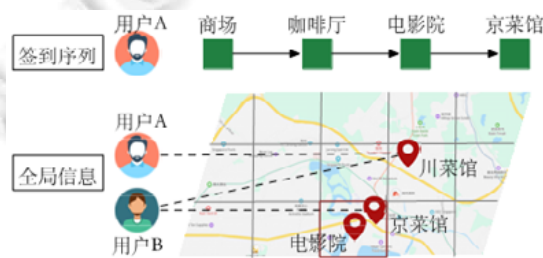


图 1 用户移动行为示例

在实际情况下, 用户的下一个移动行为不仅与局部动态信息有关, 也会受到历史移动数据中全局静态信息的影响. 例如, 从全局角度分析图 1 中用户 A 去川菜馆的决策: 一方面, 与用户 A 共同访问过川菜馆的用户 B 也去过川菜馆; 另一方面, 电影院与川菜馆位于同一商圈. 现有方法大都忽略了用户与兴趣点之间、连续签到之间隐藏的关联关系, 未能利用全局静态信息提取静态特征, 导致无法全面把握用户偏好, 影响了下一个兴趣点推荐方法的性能.

为此, 本文提出了基于全局和局部特征融合的下一个兴趣点推荐方法 GLNR (global and local feature fusion based approach for next poi recommendation). 与单纯地联合局部动态偏好和全局静态特征不同, 该方法将全局静态特征融合到用户动态行为建模中.

- 首先, 鉴于异构信息网络^[19]能够提供丰富的结构化信息, 且实体间的连通性有助于更好地学习实体间关联关系, GLNR 利用异构信息网络建模用户的历史交互数据及兴趣点的地理信息;
- 其次, 为了捕捉用户的全局静态偏好以及连续签到之间的全局依赖关系, 从全局结构中提取两类静态特征, 设计了一种表示学习方法 URRL (underlying relation representation learning). 具体地, 基于具有明确语义信息的元路径提取结构化特征, 采用相关度引导的路径采样策略生成实例路径, 同时设计层级注意力机制实现实例路径的集成, 进而得到实体间关联关系的表示, 实例路径的贡献度将作为元路径的权值;

- 最后, 在建模用户动态行为时, 将两类全局静态特征引入到学习用户行为的顺序依赖中, 采用位置与时间间隔感知的自注意力机制捕捉用户签到之间的内在联系. 结合全局静态信息与用户签到序列, 有助于探索在不同时间步上复杂的用户偏好, 提升推荐结果的有效性.

此外, 通过建模 User-POI 和 POI-POI 的显式关联路径, 赋予了 GLNR 可解释能力. 在两个真实数据集上的实验结果表明: GLNR 有效提升了推荐的准确性, 同时增强了模型的透明度和可解释性.

本文第 1 节回顾目前传统的兴趣点推荐、下一个兴趣点推荐的研究成果. 第 2 节介绍相关定义, 并提出一种基于全局和局部特征融合的下一个兴趣点推荐方法. 第 3 节通过对比实验和案例分析以验证所提方法的准确性及可解释性. 第 4 节对本文的主要工作进行总结与展望.

1 相关工作

在本节中, 从传统的兴趣点推荐和下一个兴趣点推荐两个方面来介绍相关工作.

1.1 传统的兴趣点推荐

针对传统的兴趣点推荐任务, 研究者们提出了大量方法. 其中, 主流方法侧重于将协同过滤扩展到兴趣点推荐任务中. Ye 等人^[1]提出一种基于内容的协同过滤方法, 利用泊松因子模型来捕捉地理影响和用户偏好. 孟祥福等人^[2]根据用户的社交关系和兴趣点之间的地理关系, 设计了一种具有推荐多样性的兴趣点推荐方法. Hu 等人^[3]提出一种基于标量投影最大化的用户决策分析框架, 捕捉重要的影响因素. Liu 等人^[4]利用矩阵分解学习用户在类别上的偏好. 为了获取高阶交互信息, Wang 等人^[5]提出一种基于图卷积网络的协同过滤方法 NGCF, 基于交互二分图中的高阶连通性建模, 显式地将协作信号引入到嵌入过程中. He 等人^[6]在 NGCF 的基础上进一步提出 LightGCN, 采用简单的加权和聚集器, 放弃特征变换和非线性激活, 简化了模型设计.

为缓解用户签到记录稀疏的问题, 研究者们将辅助数据融入到兴趣点推荐中^[7]. 由于异构信息网络可提供丰富的结构化信息, 有助于提高推荐准确性和可解释性, 近年来被广泛应用于兴趣点推荐任务中^[20]. Zhao 等人^[21]将元图的概念引入到推荐系统中, 并利用矩阵分解和因子分解解决异构信息融合的问题. Su 等人^[22]利用包含社交关系的异构信息网络增强用户表示, 采用图学习方法以及成对比较策略, 学习用户和兴趣点的关联关系. Han 等人^[23]提出一种时空感知的图卷积神经网络 STGCN, 将多种上下文信息融合到统一的图中, 利用图卷积网络的传播机制来学习每个节点的表示, 从而提升推荐的准确性.

1.2 下一个兴趣点推荐

随着对兴趣点推荐领域的深入探索, 下一个兴趣点推荐逐渐成为热点的研究问题. 与传统的兴趣点推荐任务相比, 下一个兴趣点推荐主要基于用户与兴趣点的交互序列, 探索用户的下一步决策. 在短期内, 用户产生的连续签到到具有很强的顺序模式. 为挖掘用户移动行为中偏好的演变, 研究者们提出了基于顺序依赖性捕捉的推荐方法, 进而更加精准地为用户推荐下一个兴趣点. Cheng 等人^[10]提出一种基于分解个性化马尔可夫链的预测方法 FPMC, 并利用个性化嵌入和区域信息将该方法扩展到下一个兴趣点推荐任务中. Feng 等人^[11]设计了一种个性化的排名度量嵌入方法 PRME, 将序列信息和地理影响结合起来.

此外, 鉴于深度学习在序列预测任务上的成功应用, 循环神经网络、卷积神经网络等深度学习技术被扩展到下一个兴趣点推荐任务中. Liu 等人^[9]针对不同的时间间隔和地理距离采用特定的转移矩阵, 提出一种时空循环神经网络 ST-RNN. Wu 等人^[12]提出了基于卷积神经网络的下一个兴趣点推荐方法, 利用内容信息, 自适应地识别签到序列中的兴趣点与预测兴趣点之间的相关性. Zhang 等人^[13]整合了元数据信息和时间信息, 基于深度游走方法编码这些知识, 从而挖掘用户下一个移动行为的隐藏意图. Feng 等人^[14]提出一种关联表示学习方法 POI2Vec, 融合地理因素建模用户移动模式, 有效地学习了用户偏好和时序特征. 通过改进长短期记忆网络, 研究者们进一步融合时空信息和用户签到序列, 以挖掘用户移动行为中的偏好^[15,16]. Zhao 等人^[17]引入时空门来捕获连续签到之间的时空关系, 提出一种时空门控网络 STGN, 通过扩展的长短期网络来更新用户偏好. Wang 等人^[18]提出了 ASGNN 方法, 将用户的签到序列构建为有向图, 采用图神经网络学习兴趣点的

表示向量, 进而捕捉用户偏好实现下一个兴趣点预测。

尽管上述方法在一定程度上提升了下一个兴趣点推荐的准确性, 但仍存在一定的局限性: 一方面, 仅基于签到的顺序依赖捕捉用户的局部动态偏好, 忽略了用户长期稳定的全局静态偏好以及连续签到之间隐藏的全局依赖关系; 另一方面, 缺乏推荐下一个兴趣点的解释能力。

2 基于全局和局部特征融合的下一个兴趣点推荐方法

与已有的下一个兴趣点推荐方法不同, 本文提出了 GLNR 方法, 融合用户签到之间的顺序依赖性和全局静态信息中蕴含的实体间关联关系来捕捉复杂的用户偏好, 进而提升推荐性能。

- 首先, 为了获取全局结构, 基于交互数据及地理信息构建异构信息网络 \mathcal{G} , 并得到用户、兴趣点和区域实体的嵌入向量;
- 其次, 设计了表示学习方法 URRL, 学习实体间的关联关系表示, 从全局结构中提取静态特征. 为了构建基于元路径的上下文, 我们提出了相关性引导的路径采样策略, 生成高质量的元路径实例. 进一步提出了层级注意力机制集成实例路径, 获得实体间关联关系表示, 将实例路径的贡献度作为元路径的权值;
- 然后, 利用 URRL 方法从两类全局静态信息中提取全局静态偏好和连续签到之间的全局依赖关系, 即 User-POI 关联关系表示和 POI-POI 关联关系表示;
- 最后, 结合两类全局静态特征更新签到到序列中的兴趣点表示, 并将其提供给推荐网络来捕捉用户移动行为的动态性, 实现下一个兴趣点推荐。

GLNR 的整体框架如图 2 所示。

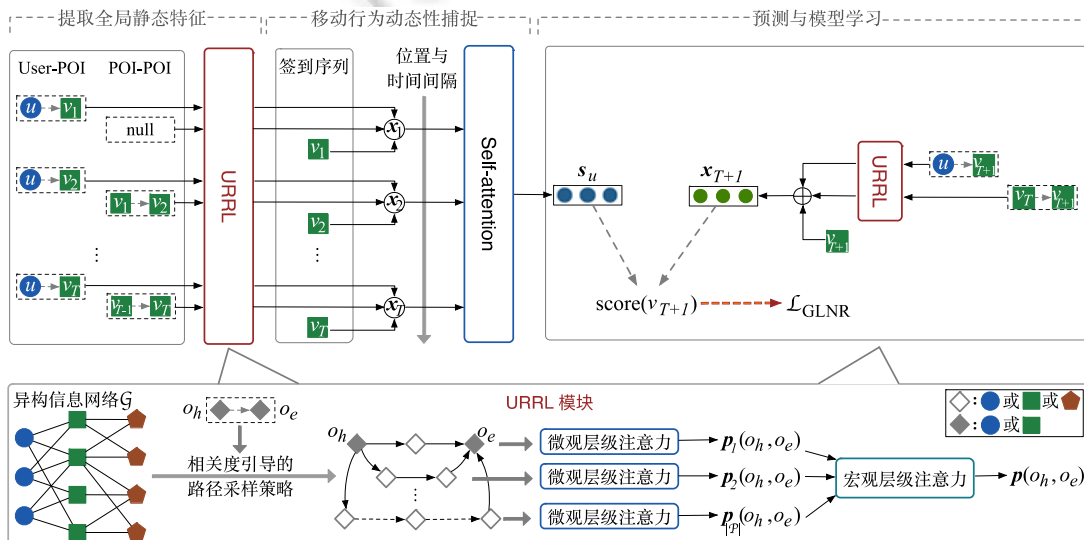


图 2 GLNR 框架图

2.1 问题定义

$\mathcal{U} = \{u_1, \dots, u_{|\mathcal{U}|}\}$ 和 $\mathcal{V} = \{v_1, \dots, v_{|\mathcal{V}|}\}$ 分别表示用户集合和兴趣点集合, 其中, $|\cdot|$ 表示集合的大小。

定义 1(用户签到序列). 用户签到序列 $cs = (cs_1, cs_2, \dots, cs_{|cs|})$ 是按时间顺序排列的签到记录, 每个签到记录是一个三元组 (u, v, t) , t 表示签到时间戳. 由于用户签到序列的长度不是固定的, 需要将其转换为固定长度为 T 的序列 $cs = (cs_1, cs_2, \dots, cs_T)$. 若签到记录数小于 T , 则在左侧添加填充项 0 直至序列长度为 T . 若签到记录数大于 T , 则仅考虑最近的 T 个移动行为。

定义 2(时间间隔). 签到序列 cs 对应的时间戳序列为 $ts = (t_1, t_2, \dots, t_T)$. cs 内任意两项 cs_i 和 cs_j 的相对时间间

隔为 $\Delta_{i,j}=|t_i-t_j|$, 可获得签到序列的时间间隔矩阵 Δ .

定义 3(异构信息网络). 异构信息网络表示为 $\mathcal{G}=(\mathcal{O},\mathcal{E})$, 其中, \mathcal{O} 表示实体对象集合, \mathcal{E} 表示边的集合. 存在一个实体类型映射函数 $\phi:\mathcal{O}\rightarrow\mathcal{A}$ 以及一个关系类型映射函数 $\varphi:\mathcal{E}\rightarrow\mathcal{R}$. \mathcal{A} 和 \mathcal{R} 分别表示实体类型集合和关系类型集合, 其中, $|\mathcal{A}|+|\mathcal{R}|\geq 2$. 换言之, 任意实体 $o\in\mathcal{O}$ 均对应一个特定的实体类型 $\phi(o)\in\mathcal{A}$, 任意边 $e\in\mathcal{E}$ 均对应一个特定的关系类型 $\varphi(e)\in\mathcal{R}$.

定义 4(元路径及实例路径). 元路径可形式化表示为 $a_h \xrightarrow{r_1} a_1 \xrightarrow{r_2} \dots \xrightarrow{r_{k-1}} a_{k-1} \xrightarrow{r_k} a_e$, 描述了起始实体类型 a_h 到终止实体类型 a_e 的复合关系. 其中, k 表示元路径中关系的数量, 元路径中任意实体类型 a_i 与关系类型 r_i 满足 $a_i\in\mathcal{A}, r_i\in\mathcal{R}$.

元路径模式下有多条实例路径. 对于路径 $p(o_h, o_e) = o_h \xrightarrow{r_1} o_1 \xrightarrow{r_2} \dots \xrightarrow{r_{k-1}} o_{k-1} \xrightarrow{r_k} o_e$ 中的任意实体 o_i , 若存在 $\phi(o_i)=a_i$, 则称 $p(o_h, o_e)$ 为该元路径的一条实例路径.

在异构信息网络中, 若存在路径使得实体 o_h 和实体 o_e 相连, 则称该路径是实体对 (o_h, o_e) 的一条关联路径, 实体 o_h 和实体 o_e 之间存在关联关系. 使实体 o_h 和实体 o_e 相连的所有元路径实例组成了实体间的关联路径集合. 下面进一步给出本文的问题定义.

问题定义 1(基于全局和局部特征融合的下一个兴趣点推荐). 对于一个用户 $u\in\mathcal{U}$, 给定用户 u 的签到序列 cs 和全局静态信息, 任务是预测用户在下一个时间步可能访问的兴趣点.

2.2 全局结构

2.2.1 构建异构信息网络

构建异构信息网络的目的是: 利用多种类型的上下文信息, 提高模型的推荐性能及可解释能力. 与其他推荐任务(如商品推荐)相比, 地理信息对于下一个兴趣点推荐是至关重要的. 然而, 现有的基于用户与兴趣点交互图的结构未能捕捉到地理影响. 为了解决这一问题, 我们构建融合兴趣点地理信息的异构信息网络 \mathcal{G} . 相比于地理位置, 将区域作为异构信息网络的节点更能充分利用空间分布和聚集信息, 易于学习兴趣点之间的地理关联关系. 因此, 在异构信息网络 \mathcal{G} 中, 如图 3 所示, 将用户、兴趣点以及区域视为节点, 即实体集合 $\mathcal{O}=\{\mathcal{U}, \mathcal{V}, \mathcal{S}\}$, 其中, \mathcal{S} 为区域集合. 实体之间具有两类不同的边关系, 即 $\mathcal{R}=\{r_{uv}, r_{vs}\}$. 下面对 \mathcal{G} 中的边及关系类型进行说明.




图 3 异构信息网络示例

用户与兴趣点的交互边 e_{uv} 表示用户 u 在兴趣点 v 有签到记录, 边的关系类型为 $\varphi(e_{uv})=r_{uv}$. 由于用户可能多次访问兴趣点, 我们给每条边分配一个标准化的关系强度. 具体来说, 边 e_{uv} 的关系强度为用户 u 在兴趣点 v 的签到数除以用户 u 的全部签到数.

兴趣点与区域的地理隶属边 e_{vs} 表示兴趣点 v 位于区域 s , 边关系类型为 $\varphi(e_{vs})=r_{vs}$. 基于兴趣点的经纬度可获取兴趣点所处区域, 但仅将兴趣点与一个区域连接, 无法全面展示兴趣点的地理信息, 例如, 靠近区域边缘的兴趣点可能与邻近区域有关. 为此, 设定兴趣点的地理影响范围, 如图 3 所示, 将与该影响范围有重叠的区域与兴趣点连接. 对于边 e_{vs} , 其关系强度为兴趣点 v 的地理影响范围和区域 s 的重叠比例.

由于一些数据集缺乏实际地理区域信息, 无法直接获取兴趣点所属区域. 为此, 我们采用空间划分方法整合地理信息. 多种方法可用于生成区域划分结果, 在本文工作中, 我们采用常用的四叉树结构, 既能够使邻

近的兴趣点划分到同一个区域, 又能捕捉区域之间的相邻关系. 首先, 将所有兴趣点构成的空间作为初始数据空间; 然后, 将数据空间递归地划分为 4 个相等的子空间, 直到子空间边长小于阈值 δ 即停止, 进而形成数据空间的区域划分结果. 此外, 以兴趣点为中心、大小为 $\delta \times \delta$ 的正方形定义为兴趣点的地理影响范围.

2.2.2 实体嵌入

将各实体的独热编码(one-hot)表示作为全连接嵌入层的输入, 利用潜在特征矩阵将输入的稀疏表示映射为稠密向量. 为了预训练 \mathcal{G} 中用户、兴趣点以及区域实体的嵌入向量, 采用 `metapath2vec`^[24] 中的随机游走提取顶点序列, 将 \mathcal{G} 中的各个实体看成自然语言中的字, 生成的顶点序列看作句子, 进而利用 `word2vec` 捕捉游走路径中实体之间的共现性. 与其他强调建模局部关系的图嵌入方法相比, `metapath2vec` 更多地侧重于同一个路径中实体的嵌入表示. 在 \mathcal{G} 中, 实体类别集合为 \mathcal{A} , 对于实体 $o \in \mathcal{O}$, 通过最大化实体 o 的异质上下文 $\mathcal{N}_d(o)$ 的条件概率, 学习各实体嵌入向量:

$$\arg \max_{\theta} \sum_{o \in \mathcal{O}} \sum_{a \in \mathcal{A}} \sum_{c_a \in \mathcal{N}_d(o)} \log p(c_a | o; \theta) \quad (1)$$

其中, 条件概率 $p(c_a | o; \theta)$ 定义为一个 softmax 函数, θ 表示参数.

2.3 提取全局静态特征

2.3.1 相关度引导的路径采样策略

具有明确语义信息的元路径有助于表达实体间的关联关系. 然而, 在获取元路径实例时, \mathcal{G} 中部分实体存在一些低重要度的邻接实体. 基于低重要度的邻接实体进一步探索路径将引入无意义的元路径实例, 因此, 我们利用实体间的相关度来引导路径采样, 以生成具有可靠语义的高质量元路径实例.

具体来说, 给定元路径模式 M , 在探索实例路径时, 每一跳均选择相关度较高的邻接实体作为后继. 为此, 我们采用基于相关度评分的方法实现后继实体采样. 对于当前实体 o_{i-1} , 下一跳候选实体集合 H_i 是与 o_{i-1} 邻接且符合元路径模式 M 的全部实体, 即 $H_i = \{o_i | (o_{i-1}, r_i, o_i) \in \mathcal{G}, o_i \notin \{o_1, \dots, o_{i-1}\}, \phi(o_i) = a_i\}$, 其中, (o_{i-1}, r_i, o_i) 表示实体 o_{i-1} 和实体 o_i 之间存在关系 r_i , a_i 表示元路径 M 中第 i 跳实体的类别. 我们使用评分函数 $f(o_{i-1}, o_i)$ 计算当前实体 o_{i-1} 和候选后继实体 $o_i \in H_i$ 的相关度, 并基于相关度对候选实体进行排序. 选择 γ 个最相关的实体作为后继, 从而实现基于相关度引导的路径采样. 实体 o_i 的后继实体集合 H_i^{cor} 如下所示, 其中, $rank(\cdot)$ 表示排名函数:

$$H_i^{cor} = \{o_i | o_i \in H_i, rank(f(o_{i-1}, o_i)) \leq \gamma\} \quad (2)$$

在计算实体 o_{i-1} 和实体 o_i 的相关度时, 考虑 o_i 的邻接实体对基于 o_i 进一步探索路径的影响, 我们利用实体 o_{i-1} 和 o_i 邻接实体 $\{o_i^1, o_i^2, \dots, o_i^{|H_{i+1}|}\}$ 之间的关联来更新实体 o_i 的表示. 首先采用点积运算, 度量实体 o_{i-1} 和 o_i 邻接实体 $o_i^n \in H_{i+1}$ 的嵌入之间的接近程度:

$$f_c(o_{i-1}, o_i^n) = \mathbf{o}_{i-1} \odot \mathbf{o}_i^n \quad (3)$$

其中, \mathbf{o} 是实体的嵌入表示向量, \odot 表示点积. 为了比较不同邻接实体对 o_i 的影响, 进一步引入 o_i 与邻接实体的边关系强度, 并利用 softmax 函数进行归一化:

$$\bar{\omega}_n = \frac{\exp(\alpha_{i,i^n} f_c(o_{i-1}, o_i^n))}{\sum_{n'=1}^{|H_{i+1}|} \exp(\alpha_{i,i^{n'}} f_c(o_{i-1}, o_i^{n'}))} \quad (4)$$

其中, α_{i,i^n} 表示实体 o_i 与实体 o_i^n 的边关系强度. 通过加权聚合邻接实体, 获得更新后的实体 o_i 表示:

$$\mathbf{o}'_i = \sum_{n=1}^{|H_{i+1}|} \bar{\omega}_n \mathbf{o}_i^n \quad (5)$$

基于更新后的实体 o_i 表示, 定义相关度函数 $f(o_{i-1}, o_i)$:

$$f(o_{i-1}, o_i) = \alpha_{i-1,i} \mathbf{o}_{i-1} \odot \mathbf{o}'_i \quad (6)$$

通过相关度引导的路径探索, 我们可以为任意实体对 (o_h, o_e) 采样并获得元路径模式 M 下的实例路径. 聚合所有元路径的实例, 形成实体对 (o_h, o_e) 之间关联路径集合 $\mathcal{P}(o_h, o_e)$, 以参与实体间的关联关系表示学习.

2.3.2 基于层级注意力机制的路径集成

为了学习实体间的关联关系表示, 进而提取全局静态特征, 我们对实体间的关联路径进行集成. 然而, 简单地使用平均池化操作集成路径信息存在较大缺陷: 首先, 忽略路径中各实体的重要性, 会限制路径的表示能力; 其次, 关联路径之间的差异性对实体间关联关系的表示至关重要. 因此, 我们设计了基于层级注意力机制的关联路径集成方法, 从微观和宏观两个层级, 分别捕捉路径中实体间的组合特征以及各实例路径的贡献度.

微观层级上, 对于每条关联路径, 利用路径中的实体来生成路径的表示向量. 自注意力机制^[25]能够自适应地计算各实体的重要性并捕捉组合特征, 为了充分考虑路径中不同实体蕴含的信息, 我们基于自注意力机制学习路径表示. 给定关联路径集合 $\mathcal{P}(o_h, o_e)$ 中的一条路径 $p_m(o_h, o_e)$, 自注意力机制的输入为路径中各实体的嵌入向量 $\mathbf{E}=[\mathbf{o}_h, \mathbf{o}_1, \dots, \mathbf{o}_{k-1}, \mathbf{o}_e]$, 定义输出为 $\mathbf{S}=[s_h, s_1, \dots, s_{k-1}, s_e]$. 自注意力机制如下:

$$\left. \begin{aligned} s_i &= \sum_j a_{ij} (\mathbf{W}_V \mathbf{o}_j), \\ a_{ij} &= \text{softmax} \left(\frac{\mathbf{W}_Q \mathbf{o}_i (\mathbf{W}_K \mathbf{o}_j)^T}{\sqrt{d}} \right) \end{aligned} \right\} \quad (7)$$

其中, d 表示维度, 缩放因子 \sqrt{d} 是用来防止内积过大; \mathbf{W}_Q 、 \mathbf{W}_K 、 \mathbf{W}_V 表示映射矩阵; \mathbf{o}_i 、 \mathbf{o}_j 为路径中实体. 由于自注意力机制是线性建模, 我们在自注意力后采用点向前馈网络来捕捉不同维度之间的相互作用, 进而赋予自注意力机制非线性能力. 定义点向前馈网络输出为 $\mathbf{H}=[\mathbf{h}_h, \mathbf{h}_1, \dots, \mathbf{h}_{k-1}, \mathbf{h}_e]$:

$$\mathbf{h}_i = \mathbf{W}_{F_2} \text{ReLU}(\mathbf{W}_{F_1} s_i + \mathbf{b}_{F_1}) + \mathbf{b}_{F_2} \quad (8)$$

其中, ReLU 为非线性激活函数, \mathbf{W}_{F_1} 、 \mathbf{W}_{F_2} 为权重矩阵, \mathbf{b}_{F_1} 、 \mathbf{b}_{F_2} 为偏移矩阵. 组合自注意力和点向前馈网络, 并将其作为自注意力模块. 尽管堆叠自注意力模块有助于提升模型性能, 但是随着堆叠层数的增加, 可能会出现过拟合、梯度消失、训练时间长等问题. 我们通过引入层归一化^[26]、随机失活^[27]和残差连接^[28]来缓解上述问题. 具体地, 定义第 l 层的 \mathbf{S} 和 \mathbf{H} 为 \mathbf{S}^l 和 \mathbf{H}^l :

$$\left. \begin{aligned} \mathbf{S}^l &= \text{LN}(\mathbf{H}^{l-1} + \text{DR}(\text{SA}(\mathbf{H}^{l-1}))), \\ \mathbf{H}^l &= \text{LN}(\mathbf{S}^l + \text{DR}(\text{FFN}(\mathbf{S}^l))) \end{aligned} \right\} \quad (9)$$

其中, SA 和 FFN 分别表示自注意力和点向前馈网络, LN 和 DR 分别表示层归一化和随机失活. 堆叠 L 层自注意力模块后的输出将作为路径的表示:

$$\mathbf{p}_m(o_h, o_e) = \text{self-attention}^L(\mathbf{E}) \quad (10)$$

其中, $\text{self-attention}^L(\cdot)$ 表示堆叠 L 层自注意力模块操作. 基于微观层级自注意力机制, 可以得到实体对之间所有关联路径的表示, 分别为 $\mathbf{p}_1(o_h, o_e), \mathbf{p}_2(o_h, o_e), \dots, \mathbf{p}_{|\mathcal{P}|}(o_h, o_e)$, 其中, $|\mathcal{P}|$ 表示 $\mathcal{P}(o_h, o_e)$ 中的路径总数.

宏观层级上, 不同关联路径的高阶信息具有差异性, 对于实体间关联关系表示具有不同的贡献度.

- 一方面, 多个元路径模式蕴含了多种语义信息, 以元路径 UVUV 和 UVSV 为例: UVUV 蕴含了基于协作的关联关系, 这是指与用户有相似签到记录的其他用户访问了目标兴趣点; UVSV 蕴含了基于地理特征的关联关系, 这是指用户在目标兴趣点附近有签到记录;
- 另一方面, 相同元路径的多个实例之间也存在差异, 例如元路径 UVUV 的两条实例路径 $u_1 \rightarrow v_2 \rightarrow u_2 \rightarrow v_3$ 和 $u_1 \rightarrow v_2 \rightarrow u_3 \rightarrow v_3$, 分别展示了用户 u_2 和 u_3 对用户 u_1 访问目标兴趣点 v_3 决策的影响.

因此, 在学习实体间的关联关系表示时, 采用宏观层级注意力机制, 学习各路径对实体间关联关系的贡献度:

$$w_m = \text{softmax}(\mathbf{W}_w \text{ReLU}(\mathbf{W}_p \mathbf{p}_m(o_h, o_e) + \mathbf{W}_h \mathbf{o}_h + \mathbf{W}_e \mathbf{o}_e + \mathbf{b}_w)) \quad (11)$$

其中, \mathbf{W}_w 、 \mathbf{W}_p 、 \mathbf{W}_h 、 \mathbf{W}_e 表示可训练参数矩阵, ReLU 为非线性激活函数. 通过集成关联路径得到实体间的关联关系表示 $\mathbf{p}(o_h, o_e)$:

$$\mathbf{p}(o_h, o_e) = \sum_{m=1}^{|\mathcal{P}|} w_m \mathbf{p}_m(o_h, o_e) \quad (12)$$

实例路径的贡献度将作为元路径的权值用于解释推荐结果.

2.4 用户行为建模

2.4.1 移动行为动态性捕捉

本文提出的 GLNR 框架基于两类全局静态信息以及用户签到序列来捕捉用户的移动偏好: 首先, 采用 URRL 方法, 从 User-POI 元路径实例和 POI-POI 元路径实例中分别学习用户对兴趣点的全局静态偏好和连续签到之间的全局依赖关系; 进而, 利用提取到的两类全局静态特征更新签到序列中的兴趣点表示. 具体地, 给定用户 u 的签到序列 cs , 对于第 t 个时间步, 将用户 u 对兴趣点 v_t 的关联关系表示 $\mathbf{p}(u, v_t)$ 以及连续签到之间的关联关系表示 $\mathbf{p}(v_{t-1}, v_t)$ 添加到当前兴趣点嵌入 \mathbf{v}_t 中:

$$\mathbf{x}_t = \mathbf{p}(u, v_t) \oplus \mathbf{p}(v_{t-1}, v_t) \oplus \mathbf{v}_t \quad (13)$$

其中, \oplus 表示连接操作. 基于更新后的兴趣点表示向量, 可形成签到序列的表示矩阵 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T]$.

鉴于 Transformer 模型在机器翻译领域中的优异表现, 其采用的自注意力机制被广泛应用于序列推荐任务中, 并获得了优于循环神经网络等方法的推荐性能^[29]. 在本文工作中, 我们利用自注意力网络对签到序列建模, 以捕捉用户签到的顺序模式, 如图 2 所示. 然而, 自注意力机制无法像循环神经网络那样捕捉序列中的相对位置, 并且忽略了连续签到的时间间隔对用户移动行为产生的影响. 为了提升自注意力机制的位置感知能力, 并且捕捉不同时间间隔蕴含的用户意图, 根据 Li 等人^[29]的方法, 我们将序列中各项的位置信息以及它们之间的时间间隔引入到自注意力机制中: 对于位置信息, 在注意力机制中对键和值分别采用可学习的位置嵌入矩阵 \mathbf{P}^K 和 \mathbf{P}^V ; 对于时间间隔, 通过缩放时间间隔 $\Delta_{i,j} = \lfloor \Delta_{i,j} / \Delta_{\min} \rfloor$ 以及裁剪操作 $\Delta_{i,j} = \min(\tau, \Delta_{i,j})$ 处理时间间隔矩阵 Δ , 其中, τ 为时间间隔上限, 最小非 0 时间间隔 $\Delta_{\min} = \min(\Delta)$, 将处理后的 Δ 映射为嵌入矩阵 Δ^K 和 Δ^V . 自注意力机制的输入为 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T]$, 定义输出为 $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_T]$. 每个输出元素 \mathbf{z}_i 是输入元素和位置嵌入、时间间隔的线性变换的加权和:

$$\left. \begin{aligned} \mathbf{z}_i &= \sum_j \omega_{ij} (\mathbf{M}_V \mathbf{x}_j + \Delta_{i,j}^V + \mathbf{P}_j^V), \\ \omega_{ij} &= \text{softmax} \left(\frac{\mathbf{M}_Q \mathbf{x}_i (\mathbf{M}_K \mathbf{x}_j + \Delta_{i,j}^K + \mathbf{P}_j^K)^T}{\sqrt{d}} \right) \end{aligned} \right\} \quad (14)$$

其中, \sqrt{d} 表示缩放因子, \mathbf{M}_Q 、 \mathbf{M}_K 、 \mathbf{M}_V 表示映射矩阵. 同样地, 组合自注意力和点向前馈网络, 形成自注意力模块. 通过堆叠自注意力机制, 自适应地计算不同时间步的签到对用户偏好的影响, 进而获得顺序感知的用户偏好 \mathbf{s}_u :

$$\mathbf{s}_u = \text{self-attention}^L(\mathbf{X}) \quad (15)$$

为了预测第 $T+1$ 个时间步用户 u 访问兴趣点 v_{T+1} 的概率, 首先更新兴趣点 v_{T+1} 的表示向量, 即 $\mathbf{x}_{T+1} = \mathbf{p}_{T+1} \oplus \mathbf{v}_{T+1}$; 然后, 根据公式(16)将序列感知的用户偏好与 \mathbf{x}_{T+1} 连接成一个向量, 并通过多层感知器 (multi-layer perception, MLP) 获得用户-兴趣点对的预测结果:

$$\mathbf{z}_{u, v_{T+1}} = \mathbf{s}_u \oplus \mathbf{x}_{T+1} \quad (16)$$

采用一个双隐层 MLP 将 $\mathbf{z}_{u, v_{T+1}}$ 投影到输出的预测结果中, 用户-兴趣点对交互可能性得分计算如下:

$$y_{u, v_{T+1}} = \sigma(\mathbf{W}_2 \text{ReLU}(\mathbf{W}_1 \mathbf{z}_{u, v_{T+1}})) \quad (17)$$

其中, \mathbf{W}_1 和 \mathbf{W}_2 分别表示两层的系数权值, ReLU 为激活函数, 输出层 σ 采用 sigmoid 函数.

2.4.2 模型学习

基于正样本和负样本, 我们使用交叉熵损失来学习模型参数. 将观察到的用户移动行为视为正样本, 反之视为负样本. 在传统交叉熵的损失函数中, 需要为每一个正样本计算所有负样本, 由于正样本和负样本存在比例不平衡的问题, 很难优化交叉熵损失. 对于成对损失函数, 只需计算一个正样本和一个负样本, 然而这会导致许多样本在整个训练过程中均未被使用. 受到 Luo 等人^[30]的启发, 我们将损失函数中的负样本数量作为超参数 β , 利用平衡采样方法随机采样负样本. 目标函数定义如公式(18)所示, 其中, \mathcal{D}^+ 表示正样本; \mathcal{D}_i^- 表示对于正样本 (u, v) 的负样本, \mathcal{D}_i^- 中的负样本数量 $|\mathcal{D}_i^-| = \beta$. 为了避免过拟合, 采用 L_2 正则化训练模型参数:

$$\mathcal{L}_{GLNR} = -\sum_{u \in \mathcal{U}} \sum_{(u,v) \in \mathcal{D}^+} (\log y_{u,v} + \sum_{(u,v') \in \mathcal{D}^-} \log(1 - y_{u,v'})) + \lambda_{\Theta} \|\Theta\|^2 \quad (18)$$

其中, Θ 表示模型参数, λ_{Θ} 是正则化系数.

3 实验分析

3.1 实验数据

我们在两个公开的 LBSNs 数据集上进行实验评估^[7], 包括 Foursquare 和 Gowalla. Foursquare 数据集采集的时间跨度为 2010 年 8 月–2011 年 7 月, 其中包含了用户在新加坡的兴趣点上进行签到产生的移动数据, 数据稠密度为 1.494%. Gowalla 数据集采集的时间跨度为 2009 年 2 月–2010 年 10 月, 其中包含了用户在加州和内华达州的兴趣点上进行签到产生的移动数据, 数据稠密度为 0.185%. 表 1 给出了数据集相应的统计信息.

表 1 数据集统计信息

数据集	#用户	#兴趣点	#签到	稠密度(%)
Foursquare	2 321	5 596	194 108	1.494
Gowalla	10 162	24 250	456 988	0.185

3.2 评价指标及基线方法

本文中, 我们采用常用的评价指标, 即召回率 Recall 和归一化折损累计增益 NDCG (normalized discounted cumulative gain), 以评估下一个兴趣点推荐方法的性能. 这两个评价指标也被广泛应用于之前的研究工作中^[6,16,20]. Recall@N 是 top-N 个推荐结果中命中用户访问将访问的兴趣点的比例, 用来衡量推荐的全面性. NDCG@N 是基于排序结果的评价指标, 用来衡量排序的质量.

我们将所提方法 GLNR 与基于异构图的兴趣点推荐方法(LightGCN^[6]、STGCN^[23])、经典的下一个兴趣点推荐方法(ST-RNN^[9]、FPMC^[10]、PRME^[11]、POI2Vec^[14])以及先进的下一个兴趣点推荐方法(STGN^[17]、ASGNN^[18])进行了比较. 当将传统的兴趣点推荐方法扩展到下一个兴趣点推荐任务中时, 由于无法捕捉签到之间的顺序依赖, 仅通过全局静态信息捕捉用户偏好. 所用 8 个基线方法如下.

- LightGCN^[6]: 一种基于图结构的协同过滤推荐方法. 通过在交互图上线性传播来学习嵌入表示, 将不同传播层嵌入信息的加权和作为最终嵌入, 去除特征转换和非线性激活, 同时以层组合方式代替自连接;
- STGCN^[23]: 一种基于时空信息感知的推荐方法. 构建一个用户记录图, 将多种上下文信息融合到一个统一的图中, 并在图卷积网络框架下学习每个节点表示;
- ST-RNN^[9]: 一种典型的基于循环神经网络的推荐方法. 分别利用特定的时间转移矩阵和特定的距离转移矩阵来建模时间和空间上下文;
- FPMC^[10]: 一种基于马尔可夫链的推荐方法. 引入一阶马尔可夫链, 以邻居兴趣点为负样本, 并将用户个性化偏好和马尔可夫链线性结合;
- PRME^[11]: 一种基于度量嵌入的推荐方法. 将空间距离作为权重, 集成序列信息、用户个性化偏好和空间影响, 从而捕捉用户移动模式;
- POI2Vec^[14]: 一种基于潜在表示学习的推荐方法. 引入用户移动行为中的粗粒度地理信息, 通过建模用户签到序列来获取用户和兴趣点关联表示;
- STGN^[17]: 一种基于增强长短期记忆网络的推荐方法. 同时学习用户的长期和短期偏好, 并引入时间门和空间门来建模连续签到之间的时空关系;
- ASGNN^[18]: 一种基于图神经网络的推荐方法. 根据用户的签到信息构建图结构, 利用图神经网络建模用户偏好和兴趣点特征, 进而基于注意力机制获取用户的长短期偏好.

3.3 实验设置

为了移除异常数据, 对于两个数据集, 均删除少于 5 个访问记录的兴趣点和用户. 与现有工作^[16]相同, 我

们将签到序列的时间窗口大小设置为 24 小时, 即把用户一天内的一组签到作为一个签到序列. 按时间对每个用户的签到进行排序, 在所有实验中, 使用用户签到数据的前 80% 作为训练集, 接下来的 10% 作为验证集, 剩下的 10% 作为测试集. 学习率设置为 0.005, 正则化系数 λ 设置为 0.001, 负样本数量 β 设置为 10, 相关实体数量 γ 设置为 10, 在 Foursquare 和 Gowalla 数据集中, 区域边长阈值 δ 分别设置为 0.8 km 和 1 km, 我们采用双层自注意力. 对于 metapath2vec, 将单个节点上的游走次数设置为 10, 随机游走步长设置为 100, 嵌入向量维度设置为 128, 窗口大小设置为 5. 在两个数据集中, 本文方法选择的元路径长度均不超过 6, 因为过长的元路径可能会引入嘈杂的语义. 其中, User-POI 的元路径包含 UVSV、UVUV、UVSVUV、UVUVSV, POI-POI 的元路径包含 VUV、VSV、VUVUV、VUVSV、VSVUV、VSVSV.

3.4 推荐准确性评估

为了评估基于全局和局部特征融合的下一个兴趣点推荐方法 GLNR 的准确性, 我们研究了以下两个问题.

- RQ1: GLNR 是否可以获得比其他基线方法更好的推荐结果?
- RQ2: GLNR 的各个模块是否均能带来性能增益?

3.4.1 RQ1: GLNR 是否可以获得比其他基线方法更好的推荐结果?

为了验证这个问题的结果, 我们分别在 Foursquare 和 Gowalla 两个数据集上将 GLNR 方法与 7 个基线方法进行了对比实验, 实验结果见表 2、表 3.

表 2 在 Foursquare 数据集上的性能比较

方法	Recall@5	Recall@10	Recall@20	NDCG@5	NDCG@10	NDCG@20
LightGCN	0.143 0	0.179 5	0.231 6	0.056 2	0.045 1	0.035 9
STGCN	0.145 9	0.181 2	0.232 8	0.059 6	0.047 5	0.036 4
ST-RNN	0.137 5	0.170 7	0.224 1	0.053 9	0.046 1	0.035 7
FPMC	0.112 5	0.160 6	0.217 7	0.039 2	0.034 7	0.027 2
PRME	0.124 1	0.164 4	0.219 8	0.057 8	0.042 1	0.033 6
POI2Vec	0.143 3	0.174 5	0.204 7	0.061 1	0.045 5	0.033 2
STGN	0.157 6	0.195 8	0.246 2	0.064 7	0.052 4	0.039 5
ASGNN	0.158 1	0.201 5	0.250 3	0.065 1	0.054 2	0.040 2
GLNR	0.170 7	0.221 2	0.264 5	0.073 9	0.062 1	0.045 5

表 3 在 Gowalla 数据集上的性能比较

方法	Recall@5	Recall@10	Recall@20	NDCG@5	NDCG@10	NDCG@20
LightGCN	0.132 7	0.180 9	0.215 4	0.051 0	0.044 1	0.034 5
STGCN	0.136 7	0.182 5	0.218 1	0.053 7	0.046 5	0.037 1
ST-RNN	0.128 1	0.162 3	0.201 8	0.041 2	0.036 5	0.028 7
FPMC	0.093 7	0.127 6	0.169 6	0.037 7	0.027 5	0.021 9
PRME	0.121 6	0.153 9	0.185 5	0.043 2	0.0373	0.029 3
POI2Vec	0.140 5	0.179 4	0.219 8	0.054 3	0.048 1	0.037 8
STGN	0.144 2	0.192 6	0.231 5	0.056 5	0.049 4	0.038 9
ASGNN	0.132 5	0.189 3	0.227 8	0.054 7	0.047 6	0.037 2
GLNR	0.150 6	0.201 2	0.242 4	0.060 1	0.054 4	0.042 7

与下一个兴趣点推荐方法 ST-RNN、FPMC、PRME、POI2Vec、STGN 以及 ASGNN 相比, 所提方法 GLNR 有着显著的性能优势: 在 Foursquare 数据集上, 与最优基线方法相比, GLNR 提升了 Recall 和 NDCG 的 7.81% 和 13.7%(3 种 N 值结果取平均, 下同); 在 Gowalla 数据集上, GLNR 同样显著优于基线方法. 定量评价结果证明了 GLNR 方法的有效性. 这一现象的原因是: GLNR 在捕捉用户签到的顺序依赖的基础上进一步引入了全局静态信息, 充分提取全局结构信息以学习用户的全局静态偏好. 已有方法致力于捕捉用户的局部动态偏好, 忽略了全局静态信息, 从而阻碍了对用户移动行为的进一步挖掘. 此外, 不同于其他推荐任务, 地理信息对于兴趣点推荐是至关重要的, GLNR 将地理信息融合到全局结构中, 以缓解数据稀疏问题.

与基于异构图的兴趣点推荐方法相比, 根据 Recall 和 NDCG 的评估结果, 所提方法 GLNR 在两个数据集上均优于 LightGCN 和 STGCN: 在 Foursquare 数据集上, 与 STGCN 相比, GLNR 提升了 Recall 的 17.5% 以及 NDCG 的 26.5%; 在 Gowalla 数据集上, GLNR 同样具有显著的性能增益. 尽管将 LightGCN 和 STGCN 扩展到

下一个兴趣点推荐任务中也给出了较优的推荐结果, 但是用户移动行为的动态性在建模用户行为模式上发挥着关键作用, 而基于异构图的兴趣点推荐方法无法学习用户连续签到之间的顺序依赖, 从而限制了下一个兴趣点推荐的性能. 同时, GLNR 能够捕捉连续签到之间隐藏的依赖关系, 利用 POI-POI 关联关系, 有助于提高推荐性能.

综上, GLNR 显著优于已有的下一个兴趣点推荐方法, 并相对于基于异构图的兴趣点推荐方法更适用于下一个兴趣点推荐任务.

3.4.2 RQ2: GLNR 的各个模块是否均能带来性能增益?

为了进一步探究 GLNR 的各个模块对模型性能的影响, 我们分别对 GLNR 进行了不同变换, 获得了以下变体方法以进行对比实验.

- GLNR-G: 在构建异构信息网络时, 仅使用用户与兴趣点的交互信息构建二分图, 忽略地理信息;
- GLNR-C: 采用随机元路径引导的采样策略生成实体间关联路径, 忽略实体间的相关度;
- GLNR-MI: 使用平均池化操作聚合路径中实体, 以生成路径表示向量, 忽略微观层级注意力机制;
- GLNR-MA: 将不同关联路径对实体间关联关系表示的贡献度视为均等, 忽略宏观层级注意力机制;
- GLNR-S: 捕捉用户移动行为的顺序模式, 以推断用户的动态偏好, 忽略全局静态信息;
- GLNR-D: 通过从全局结构中提取静态特征来推荐兴趣点, 忽略用户移动行为的顺序依赖性.

图 4、图 5 展示了 GLNR 及其各种变体的性能差异, 采用 Recall 和 NDCG 两个指标来评估各模块的有效性. 从实验结果中可以观察到:

- (1) 在两个数据集上, GLNR 的推荐性能均显著优于这几种变体. 验证了本文提出的这些模块彼此之间不冲突, 且均有助于提高模型的推荐性能;
- (2) GLNR-G 删除地理信息导致性能下降. 由于下一兴趣点推荐任务与地理因素密切相关, GLNR 利用地理信息促进实现更加精准地进行推荐;
- (3) 尽管 GLNR-C 具有较好的推荐性能, 但仍明显不如 GLNR. 与 GLNR-C 不同, GLNR 采用基于相关度引导的采样策略生成元路径实例, 证明了本文提出的采样策略的有效性;
- (4) 层级注意力机制能够更好地集成路径信息: 首先, 路径中每个实体的重要性不同, GLNR-MI 忽略实体重要性未能有效捕捉路径中实体间的组合特征; 其次, 不同的关联路径对实体间关联关系表示的影响存在差异, GLNR-MA 忽略这种差异无法实现路径集成的最佳性能;
- (5) GLNR 相对于 GLNR-S 和 GLNR-D 有较大优势. 这说明全面学习用户偏好对下一个兴趣点推荐具有重要影响, 验证了融合全局和局部特征的必要性.




图 4 在 Fourquare 数据集上 GLNR 及其变体的性能比较




图 5 在 Gowalla 数据集上 GLNR 及其变体的性能比较

3.5 案例分析: 推荐可解释性

通过将全局静态信息引入到下一个兴趣点推荐中, 不仅可以提升推荐性能, 而且能够增加模型的透明度和可解释性. 为了展示 GLNR 的可解释能力, 我们给出了一个案例并提供了可视化的解释.

从 Foursquare 数据集中随机选择一个用户, 将该用户的签到序列作为 GLNR 的输入, 进而获得最佳的推荐结果, 如图 6 所示. GLNR 给出的最佳推荐结果兴趣点 2970 是实际上用户访问的下一个兴趣点, 证明了本文提出的 GLNR 方法的准确性.

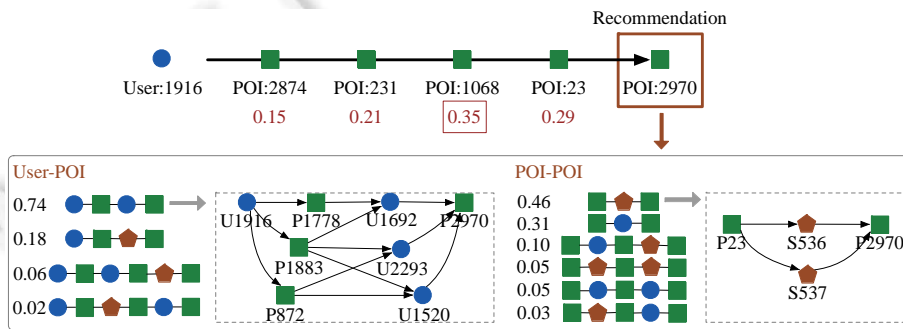


图 6 GLNR 可解释性案例

下面我们从 3 个方面进行观察与分析.

- (1) 从用户的动态交互行为角度, GLNR 有助于我们了解用户做出下一步决策的原因. 例如: 对于推荐结果兴趣点 2970, 图 6 中红色数字显示了签到序列中不同交互行为的注意力权重. 其中, 第 3 个签到记录获得了最高的注意力得分, 说明该签到记录对用户访问兴趣点 2970 的决策影响最大. 通过数据分析可以发现, 多个用户在访问兴趣点 1068 后又去了兴趣点 2970. 考虑签到之间存在顺序依赖关系, 这种解释是合理的;
- (2) 从用户的静态偏好角度, 捕捉用户 1916 和兴趣点 2970 之间的关联关系. 图 6 给出了不同元路径的注意力权重, 并以权重值最高的元路径为例, 展示了元路径实例采样, 图中仅对重要的关联路径的采样过程进行了展示. 结果表明: GLNR 能够用不同的语义路径推断用户的静态偏好, 为用户提供路径级的解释. 不同的元路径承载着不同的语义信息, 为推荐系统提供了高度的可解释性. 根据注意力权重的分布, 可以观察到, UVUV 比其他元路径模式更适合作为用户下一个移动行为的解释. 元路径模式 UVUV 表明, 与用户有相似签到记录的其他用户访问了目标兴趣点, 体现了用户与目标

兴趣点之间基于协作的关联关系;

- (3) 从连续签到角度, 我们进一步展示了兴趣点 23 与兴趣点 2970 之间的关联关系. 同样地, 我们给出元路径的注意力权重分布. 可以观察到, VSV 具有更高的注意力权重. 元路径模式 VSV 表明, 两次签到位于相同区域, 体现了连续签到之间的地理关联. 因此, 可以将 VSV 作为代表性元路径模式来理解用户的连续签到行为.

3.6 参数影响分析

为了充分探讨所提方法 GLNR 受嵌入维度大小、区域边长阈值以及负样本数量的影响状况, 分别在两个数据集上分析不同参数对性能带来的影响. 具体而言, 我们展示了在 Foursquare 数据集和 Gowalla 数据集上, GLNR 随着参数的不同, 其性能的变化趋势. 以评价指标 Recall@5 为例, 图 7-图 9 分别展示了在不同嵌入维度大小、区域边长阈值以及负样本数量下 GLNR 的性能表现.

在图 7 中, 研究所提方法的推荐性能对嵌入维度大小 d 的敏感性, 从两个数据集的角度评估嵌入维度大小对 GLNR 推荐性能的影响. 如图 7 所示: 随着嵌入维度大小的增加, 初始时推荐性能快速提升; 之后, 推荐性能的增速变得缓慢; 当 d 增加到一定程度时, 推荐性能逐渐趋于稳定. 考虑嵌入维度大小对模型复杂度的影响, 选择一个合适的嵌入维度大小是非常重要的: 一方面, 较大的 d 值会造成模型过于复杂, 而此时增加 d 产生的性能增益较小; 另一方面, 当 d 值较小时, 模型表示能力较差. 因此, 根据图 7 中的推荐性能变化趋势, 将两个数据集嵌入维度的大小设置为 128.

为了评估区域边长阈值 δ 对所提方法的推荐性能的影响, 图 8 探索了 GLNR 在两个数据集上推荐性能的变化情况. 根据图 8 可以发现: 随着区域边长阈值 δ 的增大, 推荐性能首先增加, 然后略有下降. 这一现象的原因可能是: 当区域大小超过某一阈值后, 过多不相关的兴趣点会被划入同一区域; 反之, 当区域大小过小时, 只有位置非常临近的兴趣点才能划到同一区域, 不利于准确描绘空间特征. 因此, 将图 8 中两个数据集上获得最佳性能的值作为区域边长阈值 δ 分别设置为 0.8 km 和 1 km.

图 9 显示了负样本数量从 1-30 的 Recall@5 的变化. 如图 9 所示: 当负样本数量取 10 时, 对两个数据集均产生相对稳定的推荐结果. 如果超过阈值, 则随着负样本数量的增加, 召回率逐渐降低. 与 Foursquare 数据集相比, 所提方法在 Gowalla 数据集上对负样本数量敏感度较低. 产生这一现象的原因是, Gowalla 数据集拥有更多的兴趣点. 因此, 根据图 7 中的实验结果, 最优负样本数量设置为 10.




图 7 GLNR 在不同嵌入维度大小下的性能变化

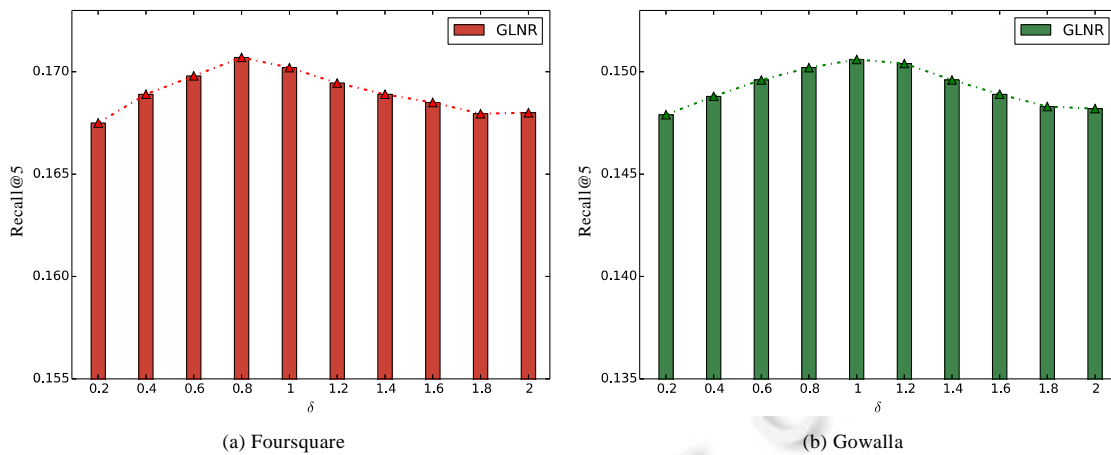


图8 GLNR 在不同区域边长阈值下的性能变化

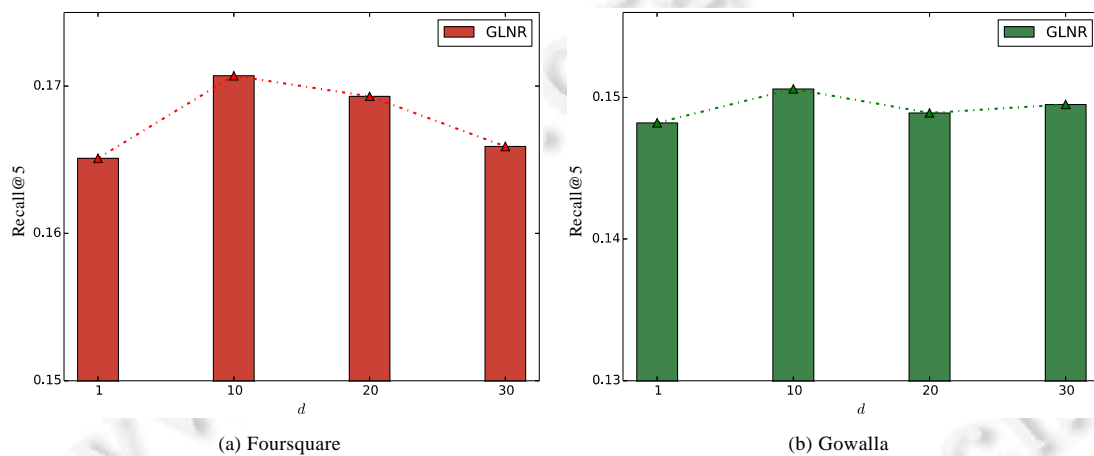


图9 GLNR 在不同负样本数量下的性能变化

4 总结

本文提出一种基于全局和局部特征融合的下一个兴趣点推荐方法 GLNR, 该方法融合用户签到之间的局部顺序依赖性和全局静态信息中蕴含的实体间关联关系来捕捉复杂的用户偏好: 首先, 构建异构信息网络, 并获得网络中实体的嵌入表示; 然后, 设计表示学习模块, 基于相关度引导的路径采样策略以及层级注意力机制学习实体间的关联关系, 以从全局结构中提取两类静态特征; 最后, 基于提取到的两类全局静态特征更新签到序列中的兴趣点表示, 并采用位置与时间间隔感知的自注意力机制捕捉用户签到之间的顺序依赖, 建模用户移动行为. 进而评估用户访问兴趣点概率, 实现下一个兴趣点推荐. 在两个真实数据集上的实验结果表明: GLNR 的推荐结果在多个指标上均优于基线方法, 并具有一定程度的可解释性.

在接下来的工作中, 我们将在下一个兴趣点推荐问题上考虑利用更丰富的辅助数据, 基于丰富的辅助数据构建异构信息网络有助于进一步挖掘全局静态特征, 从而准确地预测用户移动行为.

References:

- [1] Ye M, Yin P, Lee W, Lee DL. Exploiting geographical influence for collaborative point-of-interest recommendation. In: Proc. of the 34th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. New York: ACM, 2011. 325–334.

- [2] Meng XF, Zhang XY, Tang YH, Jia D, Qi XY, Mao Y. A diversified and personalized recommendation approach based on geo-social relationships. *Ji Suan Ji Xue Bao/Chinese Journal of Computers*, 2019, 42(11): 2574–2590 (in Chinese with English abstract). <http://cjc.ict.ac.cn/online/onlinepaper/mxf-20191114101240.pdf> [doi: 10.11897/SP.J.1016.2019.02574]
- [3] Liu X, Liu Y, Aberer K, Miao CY. Personalized point-of-interest recommendation by mining users' preference transition. In: *Proc. of the 22nd ACM Int'l Conf. on Information and Knowledge Management*. New York: ACM, 2013. 733–738.
- [4] Hu R, Lu X, Liu C, Li Y, Xiong X. Why we go where we go: Profiling user decisions on choosing pois. In: *Proc. of the 29th Int'l Joint Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2020. 3459–3465.
- [5] Wang X, He X, Wang M, Feng F, Chua TS. Neural graph collaborative filtering. In: *Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval*. New York: ACM, 2019. 165–174.
- [6] He X, Deng K, Wang X, Li Y, Zhang YD, Wang M. LightGCN: Simplifying and powering graph convolution network for recommendation. In: *Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval*. New York: ACM, 2020. 639–648.
- [7] Yuan Q, Cong G, Sun A. Graph-based point-of-interest recommendation with geographical and temporal influences. In: *Proc. of the 22nd ACM Int'l Conf. on Information and Knowledge Management*. New York: ACM, 2014. 659–668.
- [8] Meng XW, Li RC, Zhang YJ, Ji WY. Survey on mobile recommender systems based on user trajectory data. *Ruan Jian Xue Bao/Journal of Software*, 2018, 29(10): 3111–3133 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5608.htm> [doi: 10.13328/j.cnki.jos.005608]
- [9] Liu Q, Wu S, Wang L, Tan T. Predicting the next location: A recurrent model with spatial and temporal contexts. In: *Proc. of the 30th AAAI Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2016. 194–200.
- [10] Cheng C, Yang H, Lyu MR, King L. Where you like to go next: Successive point-of-interest recommendation. In: *Proc. of the 23rd Int'l Joint Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2013. 2605–2611.
- [11] Feng S, Li X, Zeng Y, Cong G, Chee YM, Yuan Q. Personalized ranking metric embedding for next new POI recommendation. In: *Proc. of the 24th Int'l Joint Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2015. 2069–2075.
- [12] Wu S, Zhang Y, Gao C, Bian K, Cui B. GARG: Anonymous recommendation of point-of-interest in mobile networks by graph convolution network. *Data Science and Engineering*, 2020, 5(4): 433–447.
- [13] Zhang Z, Li C, Wu Z, Sun A, Ye D, Luo X. Next: A neural network framework for next poi recommendation. *Frontiers of Computer Science*, 2020, 14(2): 314–333.
- [14] Feng S, Cong G, An B, Chee YM. POI2Vec: Geographical latent representation for predicting future visitors. In: *Proc. of the 31st AAAI Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2017. 102–108.
- [15] Kong D, Wu F. HST-LSTM: A hierarchical spatial-temporal long-short term memory network for location prediction. In: *Proc. of the 27th Int'l Joint Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2018. 2341–2347.
- [16] Sun K, Qian T, Chen T, Liang Y, Nguyen Q, Yin H. Where to go next: Modeling long- and short-term user preferences for point-of-interest recommendation. In: *Proc. of the 34th AAAI Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2020. 214–221.
- [17] Zhao P, Zhu H, Liu Y, Xu J, Li Z, Zhuang F, Sheng VS, Zhou X. Where to go next: A spatio-temporal gated network for next POI recommendation. In: *Proc. of the 33rd AAAI Conf. on Artificial Intelligence*. Menlo Park: AAAI, 2019. 5877–5884.
- [18] Wang D, Wang X, Xiang Z, Yu D, Deng S, Xu G. Attentive sequential model based on graph neural network for next POI recommendation. *World Wide Web*, 2021, 24(6): 2161–2184.
- [19] Shi C, Li Y, Zhang J, Sun Y, Yu PS. A survey of heterogeneous information network analysis. *IEEE Trans. on Knowledge and Data Engineering*, 2017, 29(1): 17–37.
- [20] Zhang Y, Chen X. Explainable recommendation: A survey and new perspectives. *Foundations and Trends in Information Retrieval*, 2020, 14(1): 1–101.
- [21] Zhao H, Yao Q, Li J, Song Y, Lee DL. Meta-graph based recommendation fusion over heterogeneous information networks. In: *Proc. of the 23rd ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining*. New York: ACM, 2017. 635–644.
- [22] Su Y, Li X, Zha D, Tang W, Jiang Y, Xiang J, Gao N. HREC: Heterogeneous graph embedding-based personalized point-of-interest recommendation. In: *Proc. of the 26th Int'l Conf. on Neural Information Processing*. Berlin: Springer, 2019. 37–49.

- [23] Han H, Zhang M, Hou M, Zhang F, Wang Z, Chen E, Wang H, Ma J, Liu Q. STGCN: A spatial-temporal aware graph learning method for poi recommendation. In: Proc. of the 20th IEEE Int'l Conf. on Data Mining. Piscataway: IEEE, 2020. 1052–1057.
- [24] Dong Y, Chawla NV, Swami A. Metapath2vec: Scalable representation learning for heterogeneous networks. In: Proc. of the 23rd ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. New York: ACM, 2017. 135–144.
- [25] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser L, Polosukhin I. Attention is all you need. In: Proc. of the 29th Int'l Conf. on Neural Information Processing Systems. New York: MIT, 2017. 5998–6008.
- [26] Ba JL, Kiros JR, Hinton GE. Layer normalization. arXiv:1607.06450, 2016.
- [27] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. Journal of Machine Learning Research, 2014, 15(1): 1929–1958.
- [28] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proc. of the 2016 IEEE Conf. on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016. 770–778.
- [29] Li J, Wang Y, McAuley J. Time interval aware self-attention for sequential recommendation. In: Proc. of the 13th ACM Int'l Conf. on Web Search and Data Mining. New York: ACM, 2020. 322–330.
- [30] Luo Y, Liu Q, Liu Z. STAN: Spatio-temporal attention network for next point-of-interest recommendation. In: Proc. of the 30th Int'l Conf. on World Wide Web. New York: ACM, 2021. 2177–2185.

附中文参考文献:

- [2] 孟祥福, 张霄雁, 唐延欢, 等. 基于地理-社会关系的多样性与个性化兴趣点推荐. 计算机学报, 2019, 42(11): 2574–2590. <http://cjc.ict.ac.cn/online/onlinepaper/mxf-20191114101240.pdf> [doi: 10.11897/SP.J.1016.2019.02574]
- [8] 孟祥武, 李瑞昌, 张玉洁, 纪威宇. 基于用户轨迹数据的移动推荐系统研究. 软件学报, 2018, 29(10): 3111–3133. <http://www.jos.org.cn/1000-9825/5608.htm> [doi: 10.13328/j.cnki.jos.005608]



石美惠(1993—), 女, 博士生, 主要研究领域为推荐系统, 时空数据处理.



聂铁铮(1980—), 男, 博士, 副教授, CCF 高级会员, 主要研究领域为数据质量, 数据集成.



申德荣(1964—), 女, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为 Web 数据处理, 分布式数据库.



于戈(1962—), 男, 博士, 教授, 博士生导师, CCF 会士, 主要研究领域为数据库, 大数据管理.



寇月(1980—), 女, 博士, 副教授, CCF 高级会员, 主要研究领域为推荐系统, 实体识别.