

社交关系超图网络增强的多图融合 兴趣点推荐方法*

程树林[†], 余圳强, 谢文清, 蒋京
(安庆师范大学 计算机与信息学院, 安徽 安庆 246133)

摘要: 针对现有方法在社交关系的有效提取及其与时空信息融合方面存在不足, 提出社交关系超图网络增强的多图融合兴趣点推荐方法 (MSRHN), 将局部时空增强图、全局交互超图和社交关系超图融合以实现精准推荐。局部时空增强图模型基于用户-兴趣点 (user-PoI) 交互构建时空增强图神经网络, 引入非对称传播机制建模时空依赖关系, 精确提取局部时空信息; 全局交互超图模型基于高阶 user-PoI 交互构建交互超图神经网络, 通过两步传播机制捕获高阶协同信号, 有效建模全局交互模式; 社交关系超图模型基于用户间社交连接构建社交关系超图神经网络, 融合多用户间交互信息, 深入挖掘高阶社交关系; 最终融合三种图模型生成推荐结果。在三个公开数据集上的实验表明, MSRHN 优于现有基线方法。

关键词: 兴趣点推荐; 时空增强图; 社交超图; 多图融合

中图分类号: TP391 **文献标志码:** A **文章编号:** 1001-3695(2026)04-019-1129-10
doi: 10.19734/j.issn.1001-3695.2025.08.0278

Multi-graph fusion with enhanced social relation hypergraph network for PoI recommendation

Cheng Shulin[†], Yu Zhenqiang, Xie Wenqing, Jiang Jing
(School of Computer Science and Information, Anqing Normal University, Anqing Anhui 246133, China)

Abstract: As for the limitations of existing approaches in effectively extracting social relations and integrating them with spatio-temporal information, this paper proposed multi-graph fusion with enhanced social relation hypergraph network for PoI recommendation (MSRHN), which fuses local spatio-temporal enhanced graphs, global interaction hypergraphs, and social relation hypergraphs for precise recommendation. The local spatio-temporal enhanced graph model constructed a spatio-temporal enhanced graph neural network based on user-PoI interactions, employing an asymmetric propagation mechanism to model spatio-temporal dependencies and accurately extract local spatio-temporal information. The global interaction hypergraph model built an interaction hypergraph neural network based on high-order user-PoI interactions, capturing high-order collaborative signals through a two-step propagation mechanism to effectively model global interaction patterns. The social relation hypergraph model constructed a social relation hypergraph neural network based on social connections between users, and integrated interaction information among multiple users to profoundly explore high-order social relationships. Finally, the three graph models were fused to generate recommendation results. Experiments on three public datasets demonstrate that the MSRHN method outperforms existing baseline methods.

Key words: point-of-interest (PoI) recommendation; spatio-temporal enhanced graph; social hypergraph network; multi-graph fusion

0 引言

基于位置的社交网络 (location-based social network, LBSN) 作为一种特殊的社交网络, 为用户构建了一种开放的交互平台。用户通过签到的方式分享各种兴趣点 (point-of-interest, PoI) 的体验^[1,2], 如餐厅、购物中心、旅游景点、会议场所等, 使得兴趣点推荐得到了广泛应用。兴趣点推荐不仅为用户提供感兴趣的位置点信息, 还为基于位置信息服务的提供商提供有效的决策和指导, 如广告投放与营销等。因此, 兴趣点推荐具有重要的研究价值^[3,4]。

随着机器学习和深度学习在推荐系统中的深入研究和应用, PoI 推荐受到很多学者广泛研究。根据所采用方法的不同, 现有 PoI 推荐主要分为传统方法和图神经网络方法。在传

统方法中, 以马尔可夫链和循环神经网络方法为代表。基于马尔可夫链的推荐方法^[5]和基于循环神经网络 (recurrent neural network, RNN) 的方法^[6]均对 PoI 推荐展开了相关探索, 两者皆将兴趣点推荐视为序列任务预测。为了优化这些方法的性能, 研究人员尝试通过结合地理距离、时间间隔或者时空门的方式对各种基于 RNN 的方法进行扩展。然而, 基于 RNN 的方法存在局限性, 它仅能处理短期连续访问的情况, 难以处理访问行为时间间隔较长或地理位置跨度较大的情况。近期, 基于图神经网络 (graph neural network, GNN) 的方法^[7,8]从全局视角对兴趣点的潜在表示进行细化, 在一定程度上提升了推荐的准确性和全面性。这种方法通过构建兴趣点之间复杂的关系网络, 能够挖掘出隐藏在数据中的深层次结构信息, 使兴趣点特征表示更加丰富和准确。如, Mu 等人^[7]对图的表示学习研究以及

收稿日期: 2025-08-16; **修回日期:** 2025-10-25 **基金项目:** 国家自然科学基金项目 (62306013); 安徽省自然科学基金项目 (2008085MF193)

作者简介: 程树林 (1979—), 男 (通信作者), 安徽安庆人, 教授, 硕士, CCF 会员, 主要研究方向为智能信息处理、个性化推荐; 余圳强 (2001—), 男, 安徽安庆人, 硕士研究生, 主要研究方向为个性化推荐; 谢文清 (2003—), 女, 河南许昌人, 硕士研究生, 主要研究方向为个性化推荐; 蒋京 (1990—), 男, 安徽安庆人, 副教授, 硕士, 主要研究方向为进化计算、多目标优化和机器学习。

Gong 等人^[8]对图卷积网络的研究,都为基于图的方法在兴趣点推荐领域的应用提供了坚实的理论基础和技术支撑。尽管这些方法在利用图结构方面取得了不错的成果,但它们主要关注的是兴趣点之间的固有联系,对于用户的社交关系信息以及与时空信息的融合缺乏足够的探索。目前主要存在两方面的挑战:

a) 如何从复杂位置社交网络环境中提取有效社交关系提升推荐性能。传统位置社交网络分析研究多借助统计方法或机器学习算法^[9,10]进行建模,在捕捉有效社交关系上存在一定局限性。如某位置社交网络中,用户 A 和 B 在社交平台上有很多共同好友,存在较多的重叠的兴趣点访问记录,在很大概率上他们能成为好友,但实际上在该网络中他们并不是好友关系。因此,深度挖掘复杂社交网络中隐藏的好友相关性用于 PoI 推荐值得深入探索和研究。

b) 如何将挖掘到的有效社交关系信息与时空信息进行融合提高推荐性能。针对信息的融合问题,传统方法主要依赖协同过滤思想,导致时空信息与社交信息难以实现高效结合,无法有效挖掘多维度信息之间的潜在关联,从而限制了模型的整体性能提升。因此,本文从模型融合技术角度深入探索,将从社交关系中挖掘到的信息更好地与时空信息、网络节点间高阶协作信息进行融合,从而提高 PoI 推荐方法的整体性能。

为此,本文提出一种社交关系超图网络增强的多图融合兴趣点推荐方法 MSRHN。为了捕捉 user-PoI 交互中的时空相关性,构建局部时空增强图神经网络,以非对称^[11]的方式进行聚合和传播时空信息,实现对时空信息有效的利用。为捕获全局高阶交互信息,设计了一个全局交互超图,基于两步传播机制揭示高阶协同信号,实现对高阶信息更为精准的整合与挖掘。针对社交关系增强 PoI 推荐效果,提出构建社交关系超图,揭示用户之间的高阶社交关系。最后,对局部时空增强图、全局交互超图和社交关系超图进行深度融合,实现有效的 PoI 推荐。MSRHN 方法能在 PoI 推荐中获得更好的性能,一方面得益于社交关系超图网络的增强,另一方面得益于局部时空增强图网络、全局交互超图网络和社交关系超图网络的有效融合。本文的主要工作与贡献如下:

a) 构建局部时空增强图网络对复杂的 user-PoI 交互关系、PoI 访问时间顺序和非相邻的 PoI-PoI 地理位置关系进行建模,并提出全局交互超图针对性地建模网络中用户与 PoI 之间的全局交互依赖关系,从而能够有效地提取超图网络节点中的高阶协作信号。

b) 提出社交超图网络对复杂位置社交网络中用户之间隐式社交关系进行建模,深入挖掘位置社交网络结构中的潜在信息,从而精准提取出有效的隐式社交关系,用于增强 PoI 推荐。

c) 有效融合局部时空增强图、全局交互超图和社交关系超图,克服了单一图在推荐方法中的局限性。在 NYC、TKY 和 Gowalla 三个标准公开数据集上进行的大量实验,验证了本文模型在 PoI 推荐中的有效性。

1 相关工作

1.1 PoI 推荐

PoI 推荐的核心任务是借助用户历史行为和地理位置信息,为用户推荐感兴趣的下一兴趣点。早期阶段,PoI 推荐主要围绕序列方法展开相关研究,从马尔可夫链模型^[5,12]到 RNN 模型及其多种变体模型^[6,13]。然而,这些模型存在一定的局限性,它们大多局限于对用户历史短期行为的分析,难以精准地获得用户复杂的兴趣趋势。因此,有很多研究者开始采用自注意力机制,通过显式或者隐式的方式^[14,15]对时空信息进行精细化建模,力求突破早期方法的局限。但上述方法都存在一个共同不足,即依赖于每个用户自身的轨迹信息,忽略了不同用户之间可能存在的潜在协作信号。这种协作信号对于

进一步优化 PoI 推荐的精准度,有着不可忽视的作用。最近,部分研究人员开始运用图技术来提高 PoI 推荐性能^[7,8,16-18]。然而,大多数基于图神经网络的研究没有考虑 user-PoI 交互中重要的时空信息。Rao 等人^[18]研究发现时空信息在 PoI 推荐任务中的重要价值,提出了时空知识图谱模型,可以有效地将位置社交网络图中的时空信息与兴趣点信息进行结合。但在图神经网络的信息聚合与传播过程中,依旧难以实现对这些关键信息的直接有效建模。因此,本文提出一种局部时空增强图神经网络,用于在 user-PoI 交互图的聚合和传播过程中精准捕捉时空相关性。

1.2 基于超图的 PoI 推荐

在 PoI 推荐领域,超图为处理复杂的数据关系提供了新视角^[11,19-23]。超图能够突破传统图结构的限制,用超边连接多个顶点,符合 PoI 推荐中高阶信息的表征需求。它可以将用户社交关系、兴趣偏好和地理位置等因素进行集成,构建出一个更为全面的复杂关系网络。Yan 等人^[19]发现超图在 PoI 推荐任务中的有效性,提出时空超图卷积网络,将超图与时空信息有效地结合,能够更精准地捕捉用户的兴趣偏好。与传统的图模型相比,基于超图的模型能够更深入地挖掘高阶协同信息^[20,21]。传统图模型往往局限于对一阶关系的分析,难以捕捉到深层次的用户行为模式。而超图模型则能够通过超边的反复迭代,揭示出用户与 PoI 之间的全局高阶协作信号,从而为兴趣点推荐提供更精准的依据,但依旧难以精准地捕捉到用户之间的高阶协作信号。因此,本文设计了一个可学习的交互式全局超图网络,精准捕捉用户之间的全局高阶协同信号。

1.3 基于社交关系的 PoI 推荐

在 PoI 推荐中,大量实践表明用户偏好以及最终决策都在一定程度上受好友因素影响^[24,25]。基于这一客观事实,将社交关系融入 PoI 推荐系统,借助好友之间的相似兴趣和行为信息来丰富数据资源,从而有效缓解数据稀疏问题。在早期基于社交关系的 PoI 推荐中,矩阵分解(matrix factorization, MF) 技术^[26]成为了主要方法,因为 MF 具有很好的高斯先验概率的理论解释性,使其在 PoI 推荐领域受到了广泛关注,并逐渐成为了一种常用的方法。近年来,深度学习技术蓬勃发展,为基于社交关系的 PoI 推荐拓宽了思路和途径。相较于传统模型,深度神经网络模型捕捉高层次潜在偏好方面展现出很好的优势,能让 PoI 推荐结果更精准、更贴合用户需求。如图神经网络方法凭借强大的图数据建模能力,在 PoI 推荐领域效果显著^[27-30]。传统方法和 GNN 方法处理复杂高阶社交关系存在局限性,而普通的超图方法(hypergraph method)^[31]可突破传统图的限制,但依旧难以充分挖掘高阶社交信息。因此,为利用社交关系进一步提高兴趣点推荐效果,本文提出一种社交关系超图网络,充分挖掘用户之间的高阶社交关系来增强推荐模型。

2 定义

2.1 符号定义

本文使用的符号及其定义如表 1 所示。

2.2 问题定义

设 $U = \{u_1, u_2, \dots, u_N\}$ 和 $P = \{p_1, p_2, \dots, p_M\}$ 分别为用户集合和兴趣点(PoI)集合,其中 N 和 M 分别是用户总数和 PoI 的总数。每个兴趣点 $p \in P$ 都有唯一的地理坐标元组(经度, 纬度),即 (lon, lat) 。对于每个用户 $u \in U$,按“日”作为时间间隔将其轨迹序列划分为若干会话,并得到一个轨迹序列 $T^u = \{T_1^u, T_2^u, \dots, T_n^u\}$,其中 n 表示会话的数量。每个会话表示为 $T_i^u = \{(p_j^u, t_{p_j^u}^u) | j=1, 2, \dots, k\}$,其中每个元组 $(p_j^u, t_{p_j^u}^u)$ 表示用户 u 在时间戳 $t_{p_j^u}^u$ 访问了兴趣点 p_j^u 。给定一个目标用户 u_0 和轨迹

序列 T^{u_0} , 兴趣点推荐的目标是为用户 u_0 推荐下一次可能访问的前 K 个兴趣点。

表1 符号定义表

Tab.1 Symbol definition table

符号	定义
U	用户集合
P	兴趣点集合
u	用户
p	兴趣点
T^u	用户的轨迹序列
T_i^u	会话的表示
L_u	按时间顺序排序的 PoI 集合
E^u	按时间排序的 PoI 集合中的初始嵌入向量
S^u	按时间排序的 PoI 集合中的位置嵌入向量
V^u	PoI 的地理位置信息嵌入向量
x_L^u	局部用户表示
x_L^p	局部兴趣点表示
x_H	全局兴趣点表示
x_S^u	全局用户社交表示
s_{m+1-i}	反向位置嵌入向量




图1 MSRHN方法整体框架

Fig.1 Overall framework of MSRHN method

3.2 局部时空增强图模块

局部时空增强图模块包括局部时空增强图的构造、时空信息嵌入和时空聚合层三个部分,主要目的是为捕获 user-PoI 交互聚合和传播过程中的时空相关性。

3.2.1 局部时空增强图的构造

由于用户和兴趣点间的交互以及交互的兴趣点之间存在时空关联性,故而本文构建局部时空增强图 $G_L = (V_L, E_L)$, 如图2所示。图中节点 V_L 由用户和兴趣点组成,边 E_L 由 user-PoI 交互边、PoI-PoI 时间顺序边以及非相邻 PoI-PoI 地理关系边构成。这些节点与边承载的时空信息,一方面为后续时空信息嵌入环节生成特征向量提供核心数据,另一方面为时空图聚合层实现图结构信息传播、挖掘用户与 PoI 复杂关系奠定基础——整体设计主要由时空信息嵌入和时空图聚合层两部分构成。

3.2.2 时空信息嵌入

为了充分挖掘局部时空增强图 G_L 中所蕴涵的关键时空信息,先依照时间顺序对用户 u 交互的 PoI 进行排序,生成 PoI 集合,表示为 $L_u = \{l_1^u, l_2^u, \dots, l_m^u\}$, 其中 m 代表用户 u 交互序列的

3 具体方法

3.1 整体框架

本文提出的 MSRHN 综合考虑了位置社交网络中时间、空间 and 社交关系三类信息,利用图和超图网络进行相应建模,并利用逐元素相加对它们进行融合来预测用户可能感兴趣的 PoI。MSRHN 整体框架如图1所示,主要包括局部时空增强图模块、全局交互超图模块、社交关系超图模块和多图融合与预测模块四个模块。局部时空增强图模块主要用于捕获 user-PoI 交互图中的时空相关性。全局交互超图模块采用两步传播机制挖掘位置社交网络中隐藏的用户间高阶协作信号。社交关系超图模块主要挖掘位置社交网络全局高阶社交信息,从而更好地探索社交因素在 PoI 推荐中的作用。多图融合与预测模块先引入反向位置编码信息,将其与局部时空增强图、全局交互超图的嵌入表示进行融合;然后集成局部时空增强图中的用户信息和社交关系超图中的社交信息来增强用户嵌入表示,生成最终用户嵌入表示;最后,利用学习到的兴趣点和用户表示,生成概率化推荐结果。

长度。然后,使用查找表的方式获取 PoI 在排序集合内的初始嵌入向量 $E^u = \{e_1^u, e_2^u, \dots, e_m^u\}$, 其中 $e_i^u \in \mathbb{R}^d$, d 为嵌入维数。由于交互的 PoI 存在时间顺序依赖性,本文引入位置编码^[32]来表示 PoI 之间的顺序关系,则排序的 PoI 集合的位置嵌入向量为 $S^u = \{s_1^u, s_2^u, \dots, s_m^u\}$, 其中 $s_i^u \in \mathbb{R}^d$ 。由于每个用户对于空间距离的可接受范围各不相同,需要考虑交互 PoI 之间的地理信息的影响。所以对于排序集合 L_u 中的每一对 (l_i^u, l_j^u) , 基于地理位置信息影响系数为 a_{ij} , 构造指标 $A_{geo} = [a_{ij}]$ 来精准映射用户交互的 PoI 之间边约束,如式(1)~(3)所示。

$$a_{ij} = \exp(-\text{dist}(d_i^u, d_j^u)^2) \quad (1)$$

$$\text{dist}(d_i^u, d_j^u) = 2R \arcsin x_{ij}^u \quad (2)$$

$$x_{ij}^u = \sqrt{\sin^2\left(\frac{\text{lat}_i^u - \text{lat}_j^u}{2}\right) + \cos \text{lat}_i^u \cdot \cos \text{lat}_j^u \cdot \sin^2\left(\frac{\text{lon}_i^u - \text{lon}_j^u}{2}\right)} \quad (3)$$

其中: $\text{dist}(\cdot, \cdot)$ 为半正矢距离^[11], 用于计算地球上两个点之间的最短距离; $(\text{lon}_i^u, \text{lat}_i^u)$ 表示兴趣点 p_i^u 的经纬度; $(\text{lon}_j^u, \text{lat}_j^u)$ 表示兴趣点 p_j^u 的经纬度; R 为地球半径(通常取 $R = 6371 \text{ km}$); d_j^u 表示兴趣点 l_j^u 的地理坐标。设定 Δ_d 作为距离

阈值,如果 $\text{dist}(d_i^u, d_j^u) > \Delta_d$,则 $a_{ij} = 0$;当 $\text{dist}(d_i^u, d_j^u) \leq \Delta_d$ 时,按照式(1)计算 a_{ij} 。为简化计算流程,本文使用修改的高斯核函数来表示两个 PoI 之间的地理位置信息影响,体现了两个地理位置间的影响与它们之间的距离呈反向关联的特性,并且借助参数 Δ_d 对 a_{ij} 约束控制,使其范围处于 $0 \sim 1$ 。为有效捕捉交互 PoI 之间所存在的非线性地理影响,本文引入图卷积网络^[8]




图2 局部时空增强图

Fig. 2 Local spatio-temporal enhanced graph

3.2.3 时空图聚合层

为有效聚合从交互的 PoI 邻居所采集到的关键时空信息,本文设计一种时空图聚合层。此聚合层在局部时空图中对 PoI 之间时间依赖性和非线性地理影响力进行建模。也就是,利用自注意力机制^[14]精准捕捉序列内的依赖性,并为交互中的每个 PoI 分配不同的权重,进而在获取时空消息嵌入 $\mathbf{Z}^u \in \mathbb{R}^{m \times d}$ 的基础上,进行多头缩放点积注意力^[11]操作,生成时空感知表示 $h^{Lu} \in \mathbb{R}^{m \times d}$,如式(5)~(7)所示。

$$h_i^{Lu} = \text{softmax}\left(\frac{(\mathbf{Z}^u \mathbf{W}_Q)(\mathbf{Z}^u \mathbf{W}_K)^T}{D'}\right)(\mathbf{Z}^u \mathbf{W}_V) \quad (5)$$

$$h^{Lu} = \text{FFN}([h_1^{Lu}; h_2^{Lu}; \dots; h_m^{Lu}]) \quad (6)$$

$$\text{FFN}(x) = x \mathbf{W}_0 + \mathbf{b}_0 \quad (7)$$

其中: H 为多头注意力中的头数; $[\cdot; \cdot; \cdot]$ 为串联操作,并且 $D' = \sqrt{d/H}$; $\mathbf{W}_Q, \mathbf{W}_K$ 和 $\mathbf{W}_V \in \mathbb{R}^{d \times D'}$ 为共享权重变换矩阵; $\mathbf{W}_0$ 和 $\mathbf{b}_0 \in \mathbb{R}^d$ 为可训练参数。另外,FFN(x)为前馈神经网络^[19],具有强大的特征提取能力。在网络的运行过程中,其各层神经元之间的连接权重以及神经元的偏置值都是可训练参数。通过对这些可训练参数的不断调整优化,网络能够从输入数据中自动学习并提取出有价值的特征。接下来,运用均值池化获取局部中心用户表示 $X_L^u = 1/(m+1) \sum_{i=1}^m h_i^{Lu}$,其中 $X_L^u \in \mathbb{R}^d$ 。此操作能够有效地聚合来自局部时空图中一跳邻居时空信息,从而对相应的局部节点嵌入更新优化。user-PoI 交互矩阵是 $\mathbf{R} \in \mathbb{R}^{(N+1) \times (M+1)}$,并且定义 $\mathbf{A} \in \mathbb{R}^{(N+1+M+1) \times (N+1+M+1)}$ 为局部时空增强图 $\mathcal{G}_L$ 的邻接矩阵,如式(8)所示。

$$\mathbf{A} = \begin{pmatrix} \mathbf{0} & \mathbf{R} \\ \mathbf{R}^T & \mathbf{0} \end{pmatrix} \quad (8)$$

受 LightGCN^[33]的启发,本文省略非线性变换环节,通过堆叠多个时空图聚合层展开信息传播,从而实现节点嵌入的更新,如式(9)所示。

$$\mathbf{X}_L^{(k+1)} = (\mathbf{D}_L^{-\frac{1}{2}} \mathbf{A} \mathbf{D}_L^{-\frac{1}{2}}) \mathbf{X}_L^{(k)} \quad (9)$$

其中: $\mathbf{D}_L \in \mathbb{R}^{(N+1+M+1) \times (N+1+M+1)}$ 为一个对角矩阵;第0层嵌入矩阵 $\mathbf{X}_L^{(0)} \in \mathbb{R}^{(N+1+M+1) \times d}$ 包含初始用户嵌入和 PoI 嵌入。在传播 K_L 层之后,最终的局部节点表示 $\mathbf{X}_L \in \mathbb{R}^{(N+1+M+1) \times d}$ 由聚合器生成,即通过平均池化生成。

3.3 全局交互超图模块

全局交互超图模块旨在从全局视角通过两步传播机制有效地揭示网络节点间高阶协同信号,实现对高阶信息的有效利用。

生成 PoI 的地理位置信息嵌入向量,如式(4)所示。

$$\mathbf{V}^u = \mathbf{A}_{\text{geo}} \mathbf{E}^u \mathbf{W}_{\text{geo}} + \mathbf{b}_{\text{geo}} \quad (4)$$

其中: $\mathbf{W}_{\text{geo}} \in \mathbb{R}^{d \times d}$ 为变换矩阵; $\mathbf{b}_{\text{geo}} \in \mathbb{R}^d$ 为偏置向量。然后,将初始嵌入 $\mathbf{E}^u$ 、位置编码嵌入 $\mathbf{S}^u$ 以及地理位置信息嵌入 $\mathbf{V}^u$ 进行逐元素相加,获取用户时空信息嵌入向量 $\mathbf{Z}^u = \mathbf{E}^u + \mathbf{S}^u + \mathbf{V}^u$,其中 $\mathbf{Z}^u \in \mathbb{R}^{m \times d}$ 。

3.3.1 全局交互超图构造

超图在整合传统成对关系节点具有显著的优势^[11,19-22],因此本文构建一个全局交互超图 $\mathcal{G}_H = (\mathcal{V}_H, \mathcal{E}_H)$,揭示跨会话的高阶协同信号。其中: $\mathcal{V}_H$ 为节点集合; $\mathcal{E}_H$ 为超边集合。具体地,在超图 $\mathcal{G}_H$ 中,将每个用户轨迹序列中的会话表示为一条超边,并且将会话中用户交互的 PoI 设定为超边中的节点。这里引入关联矩阵 $\mathbf{H} \in \mathbb{R}^{(M+1) \times (T+1)}$,描述超图的拓扑结构,其元素为。

$$h(v, e) = \begin{cases} 1 & \text{if } e \text{ connects } v \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

对于每个节点 $v \in \mathcal{V}_H$,其度^[21]定义为 $d(v) = \sum_{e \in \mathcal{E}_H} W_e h(v, e)$,统计节点在全部超边中出现的次数。其中: W_e 为一个随机的正权重,所有这些权重构成一个对角矩阵 $\mathbf{W} \in \mathbb{R}^{(T+1) \times (T+1)}$ 。对于每条超边 $e \in \mathcal{E}_H$,其度^[21]定义为 $d(e) = \sum_{v \in \mathcal{V}_H} H(v, e)$ 。所有的节点度和超边度分别构成对角节点度矩阵 $\mathbf{D}_H$ 和对角超边度矩阵 $\mathbf{B}$ 。

3.3.2 全局交互超图卷积网络

构建超图 $\mathcal{G}_H$ 之后,进而设计一个具有两步信息传播的超图卷积网络,即节点-超边-节点的传播机制^[21],通过迭代运算精准捕捉高阶 PoI 层级的内在关系。其中,超边充当超边内节点聚合以及跨超边传播的媒介,超图卷积网络结构如式(11)所示。

$$\mathbf{X}_H^{(k+1)} = \mathbf{D}_H^{-\frac{1}{2}} \mathbf{H} \mathbf{W} \mathbf{B}^{-1} \mathbf{H}^T \mathbf{D}_H^{-\frac{1}{2}} \mathbf{X}_H^{(k)} \quad (11)$$

其中: $\mathbf{X}_H^{(k)} \in \mathbb{R}^{(M+1) \times d}$ 表示 PoI 的嵌入,由第 k 层超图卷积网络层编码得到。因为 $\mathbf{H}^T$ 反映了超边-节点关系,所以在第一步从节点到超边的传播阶段,采用乘法 $\mathbf{H}^T \mathbf{X}_H^{(k)}$ 进行聚合。由于关联矩阵 $\mathbf{H}$ 表示节点-超边关系,故在对每个超边内的节点表示进行聚合之后,使用前乘 $\mathbf{H}$ 将信息从超边聚合到节点。在第二步从超边至节点的传播阶段,借助当前超边之外的超边信息来充实节点表示。相较于谱超图卷积 HGNN 模型^[22],本文省略了非线性激活函数,并对比 DHCN 模型^[20]所采用的简化行归一化方式,为此本文选取与 HGNN 模型一致的行归一化策略,因为 HGNN 在传播进程中较 DHCN 的简化形式 $\mathbf{D}_H^{-1} \mathbf{W} \mathbf{B}^{-1} \mathbf{H}^T$ 展现出更为出色的稳定性。对称超图拉普拉斯矩阵属于半正定矩阵,其具体形式为 $\mathbf{I} - \mathbf{D}_H^{-\frac{1}{2}} \mathbf{W} \mathbf{B}^{-1} \mathbf{H}^T \mathbf{D}_H^{-\frac{1}{2}}$,其中 $\mathbf{I} \in \mathbb{R}^{(M+1) \times (M+1)}$ 。因此 $\mathbf{D}_H^{-\frac{1}{2}} \mathbf{W} \mathbf{B}^{-1} \mathbf{H}^T \mathbf{D}_H^{-\frac{1}{2}}$ 的特征值不大于1,解决了传播中的不稳定性问题。在传播了 K_H 个超图卷积层之后,对各层所获取的 PoI 嵌入表示执行平均运算操作,进而输出全局的兴趣点表示 $\mathbf{X}_H \in \mathbb{R}^{(M+1) \times d}$ 。

3.4 社交关系超图模块

社交关系超图模块的核心目标是构建用户社交关系超图,深度挖掘高阶社交信息。这里分三步进行构建,首先根据位置社交网络节点(用户)建立社交关系图,再在此基础上构建社交关系超图,最后构造社交关系超图卷积网络精准捕捉高阶社交关系。

3.4.1 社交关系图构造

在实际应用场景中,位置社交网络中社交关系通常要么难以直接获取,要么存在部分缺失的情况。为了能够更深入地探寻用户间潜在的社交关联信息,本文引入虚拟边。具体构建方式如下:

首先,构建 user-PoI 访问数据矩阵 $A^S \in \mathbb{R}^{|\mathcal{N}| \times |\mathcal{M}|}$,其中 A_{ij} 代表用户 u_i 对兴趣点 p_j 是否访问。当两个用户 u_i 和 u_j 存在共同访问兴趣点 p_j 的行为记录时,可通过计算其行为相似度 $\text{sim}(u_i, u_j)$ 以量化其偏好一致性。然而,由于 user-PoI 交互数据的高维性与稀疏性,直接基于共现行为构建的相似度矩阵往往存在稀疏问题。为缓解该问题,引入矩阵分解技术,通过对原始稀疏矩阵进行低秩近似,挖掘用户与兴趣点背后的潜在特征表示,从而实现稀疏相似性矩阵的有效降维,进一步提升相似度估计的可靠性。矩阵分解旨在将矩阵 A^S 分解为两个低秩矩阵 $X \in \mathbb{R}^{|\mathcal{N}| \times d}$ 和 $Y \in \mathbb{R}^{|\mathcal{M}| \times d}$ 的乘积,即 $A^S \approx XY^T$,其中 d 是分解后的潜在特征维度,通过该过程揭示潜在特征。

其次,在满足共同访问兴趣点条件的用户 u_i 和 u_j 之间构建一条虚拟边,以此作为连接潜在在社交关系的纽带,为进一步解析复杂的社交网络结构奠定基础。基于这些虚拟边,运用图论相关算法,将虚拟边具象化为社交关系图中的连接。构建社交关系图 $G_s = (\mathcal{V}_s, \mathcal{E}_s)$,其中 $\mathcal{V}_s$ 为节点集合, $\mathcal{E}_s$ 为边集合。具体地,在社交关系图中,将用户表示为节点,并且将虚拟边表示为社交边,从而构建社交关系图,为社交网络分析提供直观且易于理解的表达形式。

3.4.2 社交关系超图构造

超图在捕捉复杂关系上具有显著优势^[34],构建社交关系超图 $G_s^* = (\mathcal{V}_s^*, \mathcal{E}_s^*)$ 可深度挖掘潜在的高阶社交互动模式。通常情况下社交关系图呈现出稀疏的特点,在一定程度上影响社交关系更深入的分析。为此,本文采用掩盖图^[35]的方式来减少稀疏性所带来的不利影响。经过深入的研究,固定的掩盖图在特征捕获方面存在一定的局限性,它仅仅只能捕获一阶特征。然而,若将固定掩盖图与随机掩盖图进行叠加使用,能够突破局限,进而捕获到二阶特征。具体的构建步骤如下:

首先,以特定方式从社交关系图 $G_s = (\mathcal{V}_s, \mathcal{E}_s)$ 生成 6 张社交掩盖图。设社交关系图 G_s 的边数量为 $|\mathcal{E}_s|$,对于前 5 张社交掩盖图分别记为图 $G_{s_1}, G_{s_2}, G_{s_3}, G_{s_4}, G_{s_5}$,每张图各自固定掩盖社交关系图中边的数量为 $0.2|\mathcal{E}_s|$,且这 5 张社交掩盖图固定掩盖的边数量总和为 $5 \times 0.2|\mathcal{E}_s| = |\mathcal{E}_s|$;第 6 张掩盖图记为 G_{s_6} ,则随机选择并掩盖社交关系图边数量的 20%,即 $0.2|\mathcal{E}_s|$ 。然后,将 6 张掩盖图叠加,对于任意两个用户 u_i 和 u_j ,设叠加后这两个用户之间边的数量为 n_s ,若 $n_s > 4$,则形成一条超边,超边中的用户 u_i 和 u_j 为节点;若 $n_s \leq 4$,则不会形成超边。经过上述步骤,根据所形成的超边以及相应的节点,构建出一个超图 $G_s^* = (\mathcal{V}_s^*, \mathcal{V}_s^*)$ 。为了描述超图的拓扑结构,引入关联矩阵 $B_s \in \mathbb{R}^{|\mathcal{N}| \times |\mathcal{S}|}$, $|\mathcal{S}|$ 表示超边总数,其元素定义如式(12)所示。

$$h_s(v, e) = \begin{cases} 1 & \text{if } n_s > 4 \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

3.4.3 社交关系超图卷积网络

构建超图 G_s^* 之后,设计一个超图卷积网络,其核心作用在

于通过迭代运算精准捕捉高阶社交关系。对于节点 u ,其特征向量更新如式(13)所示。

$$X_S^{(k+1)} = B_S W_S X_S^{(k)} \quad (13)$$

其中: $X_S^{(k)} \in \mathbb{R}^{|\mathcal{N}| \times d}$ 为用户嵌入,它是由第 k 层超图卷积网络层编码得到; W_S 一个可训练矩阵。在传播了 K_S 个超图卷积层之后,对 layers 所获取的用户表示执行求和运算,进而输出全局用户 u 表示 $X_S \in \mathbb{R}^{|\mathcal{N}| \times d}$ 。

然后,利用自注意力机制^[19],通过分配不同的注意力权重来获得全局用户 u 的社交嵌入表示 $x_S^u \in \mathbb{R}^d$,如式(14)所示。

$$x_S^u = \text{softmax} \left(\frac{(X_S W_Q)(X_S W_K)^T}{\sqrt{d}} \right) (X_S W_V) \quad (14)$$

其中: W_Q, W_K 和 $W_V \in \mathbb{R}^{d \times d}$ 为共享权重变换矩阵; d 为特征维度。

3.5 多图融合与预测模块

此模块可有效融合局部时空增强图、全局交互超图和社交关系超图三个方面的信息,预测用户感兴趣的下一个 PoI。融合过程主要分为两个步骤,即先集成 PoI 嵌入表示和用户嵌入表示,再融合社交关系超图进行预测。

3.5.1 多图融合

在 PoI 推荐中,最终的推荐决策在很大程度上受用户近期偏好影响。不同于传统方法对交互过的 PoI 表示直接进行简单聚合或拼接,而是提出引入反向位置嵌入技术^[20]增强用户时间偏好。通过引入反向位置嵌入能让模型更好地捕捉用户兴趣点的时间顺序,距离当前时间越近的兴趣点,对应的反向位置嵌入权重越大,从而增强了对用户近期偏好的体现,实现时间增强。在完成从局部时空增强图与全局交互超图中对 PoI 嵌入表示的学习后,采用逐元素相加的方式获取所有 PoI 的嵌入表示,即 $X^L = X_L^L + X_H$,其中 $X_L^L \in \mathbb{R}^{|\mathcal{M}| \times d}$ 和 $X_H \in \mathbb{R}^{|\mathcal{M}| \times d}$ 分别表示局部时空增强图和全局交互超图中所得到的 PoI 嵌入表示。对用户 u 的排序序列 T_u 中的第 i 个兴趣点经时间增强后的嵌入 x_i^{u*} 如式(15)所示。

$$x_i^{u*} = \tanh(W_1[x_i^u; s_{m+1-i}] + b_1) \quad (15)$$

其中: $W_1 \in \mathbb{R}^{d \times 2d}$ 和 $b_1 \in \mathbb{R}^d$ 分别表示可训练参数矩阵和参数向量; $x_i^u \in \mathbb{R}^d$ 可从兴趣点嵌入 X^L 索引中得到; $s_{m+1-i} \in \mathbb{R}^d$ 表示反向位置嵌入。为此,本文利用软注意力机制^[11],通过分配不同的注意力权重来获得用户 u 经时间偏好增强后的嵌入 $x_T^u \in \mathbb{R}^d$,如式(16)(17)所示。

$$x_T^u = \sum_{i=1}^m \alpha_i x_i^{u*} \quad (16)$$

$$\alpha_i = q^T \sigma(W_2 x^{u*} + W_3 x_i^{u*} + b_2) \quad (17)$$

其中: $q \in \mathbb{R}^d, W_2, W_3 \in \mathbb{R}^{d \times d}$ 和 $b_2 \in \mathbb{R}^d$ 是可训练的注意力参数矩阵; $x^{u*} \in \mathbb{R}^d$ 是通过用户对所有交互过的 PoI 嵌入运用平均池化(mean-pooling)的方式进行处理后得到的结果; σ 表示 sigmoid 激活函数。在依次获取到用户的局部表示 $x_L^u \in \mathbb{R}^d$ 、时间增强型用户表示 $x_T^u \in \mathbb{R}^d$ 以及基于社交关系的用户表示 $x_S^u \in \mathbb{R}^d$ 之后,采用逐元素相加的方法融合最终的用户表示,即 $u = x_L^u + x_T^u + x_S^u, u \in \mathbb{R}^d$ 。

3.5.2 兴趣点预测

利用内积运算得到最终用户表示 u 与目标 PoI 表示 $x^p \in \mathbb{R}^d$ 的得分,通过 softmax 函数^[19]进行兴趣点概率预测:

$$\hat{y}_i^u = \text{softmax}(u^T x^p) \quad (18)$$

其中,目标学习函数采用交叉熵损失函数^[18],如式(19)所示。

$$\mathcal{J} = - \sum_{u \in \mathcal{N}} \sum_{i \in \mathcal{L}_u} Z_{i,j}^u \log(\hat{Z}_{i,j}^u) + \lambda \|\Theta\|_2 \quad (19)$$

其中: $Z_{i,j}^u$ 为一个指示变量,当 p_j 是用户在第 i 个会话之后实际访问 PoI 时, $Z_{i,j}^u = 1$ 否则, $Z_{i,j}^u = 0$; $\|\Theta\|_2$ 表示在参数 λ 控制下,对所有参数进行 L2 正则化以防止过拟合。

4 实验

4.1 实验准备

4.1.1 数据集

本文实验采用了 Foursquare-NYC (NYC)^[36]、Foursquare-TKY (TKY)^[36] 和 Gowalla^[37] 数据集三个公开位置社交网络数据集。对于 NYC 和 TKY 数据集,删除了少于 5 个用户访问的不受欢迎的 PoI,把每个用户的签到序列依据一天的时间跨度拆分成多个会话,并删除那些包含少于 3 条记录的会话,会话少于 3 个的非活跃用户也会被过滤掉。而对于 Gowalla 数据集,删除了少于 10 个用户访问的不受欢迎的 PoI,把每个用户的签到序列依据一天的时间跨度拆分成多个会话,并删除那些包含少于 4 条记录的会话,会话少于 5 个的非活跃用户也会被过滤掉。每个用户前 80% 会话数据用于训练,其余数据用于测试。预处理后数据集统计信息如表 2 所示。

表 2 数据集统计数据

Tab.2 Statistical data of the datasets

dataset	# users	# PoI	# check-ins	# sessions	sparsity/%
NYC	834	3 835	44 686	8 841	98.61
TKY	2 173	7 038	308 566	41 307	97.82
Gowalla	809	1 977	68 534	8 878	97.11

4.1.2 评价指标

为验证本文方法 MSRHN 的性能,采用了 recall@K 和归一化折扣累积增益 NDCG@K 两个广泛使用的评价指标。recall@K 是信息检索和推荐系统领域中常用的评估指标,衡量的是在所有相关的物品中,前 K 个推荐结果中能够正确召回的比例,如式(20)所示。

$$\text{recall}@K = \frac{n}{N} \quad (20)$$

其中:n 为前 K 个推荐结果中与用户真实相关的物品数量;N 为该用户的所有真实相关物品的总数。NDCG@K 是一种用于衡量推荐系统或者信息检索系统排序质量的指标,考虑推荐结果的相关性和排序位置两个因素,如式(21)和(22)所示。

$$\text{DCG}@K = \sum_{i=1}^K \frac{r_i}{\log_2(i+1)} \quad (21)$$

$$\text{NDCG}@K = \frac{\text{DCG}@K}{\text{IDCG}@K} \quad (22)$$

其中: r_i 为第 i 个项目的相关性得分,折扣累积增益 IDCG 是在理想情况下(即所有相关项目按照相关性得分从高到低排序)的 DCG 值。假设已经知道所有可能推荐项目的相关性得分,将它们从高到低排序,再按照 DCG 的计算方法计算 IDCG 的值。

4.1.3 基线方法

本文选取了 8 个目前典型的主流 PoI 推荐方法进行比较,分为三类:a)基于 RNN 的方法 STGN 和 LSTPM;b)基于 GNN 的方法 LightGCN;c)基于图或超图对比学习的方法 DisenPoI、HCCF、DHCN、MSTHN 和 ASTHL。具体描述如下。

1) 基于 RNN 的方法

STGN^[38]:一种基于增强长短期记忆网络的推荐方法,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。

LSTPM^[39]:一种基于长短期记忆网络的推荐方法,通过非局部网络和地理扩张的长短期记忆网络,捕捉用户的长短期偏好,并挖掘隐藏在用户签到序列中的复杂时空模式。

2) 基于 GNN 的方法

LightGCN^[33]: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。

3) 基于图或超图对比学习的方法

DisenPoI^[40]:一种基于解耦表示学习的推荐方法,通过解耦策略将用户行为模式和兴趣点特征进行分离学习,并利用多模态数据融合技术,整合用户的时空信息、社交关系以及历史签到记录。

HCCF^[41]:一种基于超图卷积协同过滤的推荐方法,通过捕捉用户与物品之间的高阶交互关系和潜在特征,并利用超图卷积层来建模用户、物品及它们之间复杂关联的拓扑结构。

DHCN^[20]:一种基于动态超图卷积网络的推荐方法,通过挖掘用户行为的动态变化和复杂的高阶关联关系,并引入时间感知机制和超图卷积操作来建模用户与物品交互随时间演变的时空特征。

MSTHN^[23]:一种基于多视角时空增强超图网络的推荐方法,融合局部时空增强图和全局交互超图信息,引入反向位置嵌入增强用户时间偏好,挖掘用户行为的高阶协作信号和复杂时空特征。

ASTHL^[23]:一种自适应的时空超图融合学习方法,融合时间和空间维度的超图信息,设计以解耦后的兴趣点为中心的学习来分离时空因素,运用跨视图对比学习提升兴趣点表示质量,挖掘兴趣点交互中的互补效应和复杂时空模式。

4.1.4 实验环境及参数设置

本文全部实验在一台 24 GB 的 NVIDIA GeForce RTX 4090 D GPU 深度学习主机上进行,并借助 PyTorch 1.10.2 深度学习框架。在优化器的选择上,采用 Adam 优化器,其具体参数设置如下:学习率设定为 1×10^{-3} ,此学习率旨在训练过程中平衡收敛速度和模型的泛化能力;权重衰减系数为 1×10^{-7} ,权重衰减的目的是防止模型过拟合,通过对权重的约束来提高模型的稳定性;设置丢弃率为 0.3,丢弃率的设定目的是在训练过程中随机丢弃一部分神经元,增强模型的泛化能力。用户嵌入和 PoI 嵌入采用相同维度大小,即 $d = 128$,同时依据经验把 2.5 km 作为距离阈值。针对不同数据集,实施不同超参数配置:NYC 数据集设置 BatchSize 为 400、最大序列长度为 50,TKY 数据集设置 BatchSize 为 1 000、最大序列长度为 200, Gowalla 数据集则设置 BatchSize 为 400、最大序列长度为 14,并对所有数据集进行序列填充操作以统一输入维度。在模型训练过程中,以交叉熵损失函数(cross entropy loss)作为优化目标,用于量化预测概率分布与真实标签之间的差异。通过实时监控损失函数值的动态变化,分析模型收敛特性;训练初期,因参数随机初始化导致损失值处于高位;随着训练迭代推进,Adam 优化器依据反向传播计算的梯度信息自适应调整参数,促使损失函数持续下降。实验结果表明,在 NYC、TKY 和 Gowalla 三个数据集上,经过 100 个训练周期(epoch)后,损失函数均呈现稳定收敛态势,最终收敛值分别达到 0.009、0.05 和 0.008,验证了模型在不同数据集上的有效性与稳健性。

4.2 社交关系有效性的验证

为验证基于位置数据构建的虚拟社交边能否真实反映现实社交关系,本文选取具有真实社交关系标注的位置社交网络数据集 Gowalla 作为研究对象。Gowalla 包含 196 591 个用户的 950 327 条好友关系记录,同时涵盖 1 280 969 个 PoI,为研究提供了丰富的数据支撑。具体有效性验证结果如表 3 所示。

根据表 3 实验数据可得出以下分析:a)阈值对虚拟社交边生成的影响。随着阈值从 9 降至 6,虚拟社交边数量从 622 251 条增至 1 752 207 条,呈现出指数级的增长趋势。这表明阈值作为虚拟社交边生成的核心参数,较低的阈值显著放宽了关系预测条件,使更多基于位置共现的用户关系被识别为虚拟社交边。b)预测关系与真实关系的偏差分析。差值列数据显示,虚拟社交边数量与真实社交关系数量的差异先减小后增大。阈值为 8 时,差值为 112 990 条,反映出该参数设置下虚拟社交

边数量与真实社交边数量最为接近;而阈值为 6 时,差值达 801 880 条,说明过度降低阈值会导致大量冗余虚拟社交边产生,偏离现实社交网络结构。c) 准确率与召回率的关系。准确率随阈值降低从 48.95% 提升至 100%,意味着预测关系的正确性逐步提高;但召回率却从 74.76% 降至 54.23%,表明在追求高准确率时,模型可能将大量非真实关系误判为虚拟社交边,导致真实关系的识别效率下降。这种准确率与召回率的反向变化,揭示了虚拟社交边预测中存在过拟合风险。

表 3 虚拟社交边的有效性验证

Tab. 3 Validation of the effectiveness of virtual social ties

序号	阈值	虚拟社交边数量	有效社交边数量	差值	准确率/%	召回率/%
1	9	622 251	465 215	328 076	48.95	74.76
2	8	837 337	679 331	112 990	71.48	81.13
3	7	1 177 884	950 327	227 557	100	80.68
4	6	1 752 207	950 327	801 880	100	54.23

注:阈值:取用户共同访问 PoI 的数量作为阈值,验证不同阈值下虚拟社交关系有效性;差值 = |真实社交边数量 - 虚拟社交边数量|。

综上所述,本文基于 Gowalla 数据集的实证分析表明,基于位置数据构建的虚拟社交边在一定阈值范围内能够有效反映现实社交关系。阈值的调整显著影响虚拟社交边的生成数量、与真实关系的偏差程度以及模型的准确率和召回率。当阈值设置为 8 时,虚拟社交边数量与真实社交边数量最为接近,召回率达到最佳效果;而阈值过低时虽能实现预测关系对真实关系的完全覆盖,却会引发准确率与召回率失衡的过拟合问题。

4.3 性能比较

表 4~6 分别给出了本文方法与基线方法在三个数据集上的综合性能比较结果,其中最优和次优性能分别用粗体和下划线表示。

总体上,表 4~6 实验结果表明,在三个数据集上的实验比较,本文方法 MSRHN 有效地提高了兴趣点推荐的 recall 和 NDCG 指标,综合性能有较大的提升。在 NYC 数据集上,本文 MSRHN 在 recall@K 和 NDCG@K 指标上,相较于基线方法有显著的提升。与基线方法中的次优结果进行对比,本文 MSRHN 在 recall@5 上提高了 11.48%,而在 NDCG@5 指标上提升更大,达到 12.67%。在 TKY 数据集上,MSRHN 依旧表现较好,与基线方法中表现最好的模型 MSTHN 比较,MSRHN 在 recall@5 指标上提升了 7.74%,在 NDCG@5 指标上也有 6.50% 的提升。同样在 Gowalla 数据集上,MSRHN 仍然表现较好,与基线方法中最好的模型 MSTHN 比较,MSRHN 在 recall@5 指标上提升了 11.44%,在 NDCG@5 指标上也有 12.21% 的提升。MSRHN 之所以能取得更好的性能,主要得益于以下两点:a) 社交关系超图网络利用高阶连接优势,打破传统图结构限制,挖掘位置社交网络深层信息,精准提取有效社交关系,显著增强 PoI 推荐效果;b) 局部时空增强图、全局交互超图 and 社交关系超图的有效融合,弥补了单一图在推荐中的不足。

另外,在基线方法中,STGN 和 LSTPM 在三个数据集中都表现不佳,因为模型都是通过循环神经网络处理序列数据,捕捉用户签到到序列中的时间依赖关系。然而用户的签到行为在时间、地点等方面呈现出多样化、不规则或难以预测的特征,它不能有效捕获用户行为模式和偏好,导致推荐的准确性较低。而 LightGCN 在三个数据集中都表现出比 STGN 和 LSTPM 更优越的性能,这是因为 LightGCN 能够将用户和物品建模为图中的节点,通过图的边来表示用户与物品之间的交互关系,能更好地捕捉全局结构信息。但在面对动态变化的用户行为和物品信息时,它不能实时更新图结构,可能导致推荐的准确性下降。DisenPoI、HCCF、DHCN、MSTHN 和 ASTHL 在三个数据集中都表现出比 LightGCN、STGN 和 LSTPM 更优越的性能,主要是因为它们通过对比学习或利用超图结构来处理物品信息动态变化,但未考虑其他上下文信息,尚不能达到 MSRHN 的综合性能。

表 4 NYC 数据集性能

Tab. 4 Performance of the NYC dataset

method	recall@5	recall@10	NDCG@5	NDCG@10
STGN	0.237 1	0.259 4	0.226 1	0.230 7
LSTPM	0.249 5	0.266 8	0.242 5	0.248 3
LightGCN	0.322 1	0.348 8	0.295 8	0.304 2
DisenPoI	0.357 7	0.383 1	0.297 9	0.307 1
HCCF	0.353 4	0.374 5	0.302 5	0.313 4
DHCN	0.374 5	0.396 6	0.312 6	0.320 3
MSTHN	0.407 6	0.439 8	0.361 2	0.370 2
ASTHL	0.411 9	0.447 7	0.359 7	0.370 7
MSRHN	0.459 2	0.488 0	0.407 0	0.415 8
improved/%	11.48	9.00	12.67	12.16

表 5 TKY 数据集性能

Tab. 5 Performance of the TKY dataset

method	recall@5	recall@10	NDCG@5	NDCG@10
STGN	0.211 2	0.258 7	0.148 2	0.158 9
LSTPM	0.220 3	0.270 3	0.155 6	0.173 4
LightGCN	0.221 3	0.259 4	0.197 7	0.209 8
DisenPoI	0.269 2	0.331 4	0.226 3	0.233 2
HCCF	0.268 9	0.325 3	0.232 5	0.242 9
DHCN	0.317 2	0.345 4	0.244 2	0.254 3
MSTHN	0.337 8	0.392 7	0.256 7	0.272 1
ASTHL	0.296 7	0.350 9	0.235 8	0.250 6
MSRHN	0.364 3	0.403 1	0.273 4	0.285 7
improved/%	7.74	2.64	6.50	4.99

表 6 Gowalla 数据集性能

Tab. 6 Performance of the Gowalla dataset

method	recall@5	recall@10	NDCG@5	NDCG@10
STGN	0.146 2	0.195 1	0.103 5	0.119 0
LSTPM	0.199 3	0.259 6	0.139 9	0.159 7
LightGCN	0.215 0	0.261 1	0.166 9	0.184 2
DisenPoI	0.234 3	0.288 7	0.177 6	0.190 4
HCCF	0.232 1	0.286 3	0.181 5	0.195 6
DHCN	0.257 6	0.309 4	0.201 3	0.208 5
MSTHN	0.289 3	0.341 5	0.219 4	0.235 6
ASTHL	0.275 1	0.314 3	0.186 7	0.198 2
MSRHN	0.322 4	0.372 0	0.246 2	0.263 1
improved/%	11.44	8.93	12.21	11.67

除此之外,通过对不同数据集上各模型综合性能的分析还发现,本文模型及基线模型在 NYC 数据集上展现出的综合性能整体要优于 TKY 和 Gowalla 数据集。这是因为 NYC 数据集中用户之间平均社交关系相较于 TKY 和 Gowalla 数据集呈现出更为紧密和集中的状态,有利于模型从中学习到更为丰富的社交信息,进而促使各模型在 NYC 数据集上能够有更为良好的综合性能表现。

4.4 消融实验

为了验证本文 MSRHN 各个组件模块的作用,在三个数据集上面进行了消融实验,为简化过程,仅在 recall@10 和 NDCG@10 指标上进行消融实验分析。本文设计了五种 MSRHN 变体方法:a) MSRHN-w/o-local,去除局部时空增强图神经网络模块;b) MSRHN-w/o-global,去除全局交互超图神经网络模块;c) MSRHN-w/o-social,去除社交关系超图模块;d) MSRHN-local-w/o-spatial,去除局部视图中的空间信息;e) MSRHN-local-w/o-temporal,去除局部时空图中的时间信息。各消融实验结果如表 7 所示。

分析表 7 和图 3 结果可知:a) 当去除局部时空增强图神经网络模块(MSRHN-w/o-local)时,三个数据集的 recall@10 和 NDCG@10 指标均有所下降,表明局部视图模块对推荐的正确性和质量有一定影响;b) 当删除全局交互超图神经网络模块(MSRHN-w/o-global)时,三个数据集的 recall@10 和 NDCG@10 指标明显下降,充分显示了全局超图网络的重要性,它突破了传统图仅能表达节点间二元关系的局限,对推荐效果有较大影响;c) 当去除社交关系超图模块(MSRHN-w/o-social)时,三个数据集的 recall@10 和 NDCG@10 指标均有一定的下降,表明

社交关系对推荐的正确性和质量有一定影响;d)当去除局部视图中的空间信息(MSRHN-local-w/o-spatial)时,三个数据集中的 recall@10 和 NDCG@10 指标大幅度下降,表明空间信息对性能的影响很大,与现实情况相符。因为实际生活中,距离相近且符合用户兴趣倾向的 PoI,用户访问的概率更大。最后,当去除局部视图中的时间信息(MSRHN-local-w/o-temporal)时,三个数据集的 recall@10 和 NDCG@10 指标有轻微下降,表明时间信息相

对空间信息来说,对推荐效果的影响不是很大。

综上所述,空间信息在局部视图中的作用很重要,其去除后指标大幅度下降。全局交互超图模块对推荐效果的影响较大,其去除后指标明显下降。社交关系超图模块和局部时空增强图神经网络模块对推荐效果有一定影响,但相对前两者而言,影响程度适中。局部视图中的时间信息对推荐效果有影响,但在所有因素中,其影响相对较小。

表 7 消融结果

Tab. 7 Ablation results

method	NYC		TKY		Gowalla	
	recall@10	NDCG@10	recall@10	NDCG@10	recall@10	NDCG@10
MSRHN-w/o-local	0.466 5	0.400 5	0.383 5	0.262 6	0.323 3	0.241 4
MSRHN-w/o-global	0.455 6	0.392 5	0.360 1	0.253 1	0.319 7	0.197 4
MSRHN-w/o-social	0.475 2	0.405 0	0.387 2	0.275 9	0.324 3	0.245 2
MSRHN-Local-w/o-spatial	0.373 5	0.259 2	0.247 8	0.145 0	0.268 0	0.138 8
MSRHN-Local-w/o-temporal	0.476 7	0.410 0	0.402 1	0.283 1	0.368 8	0.250 7
MSRHN	0.488 0	0.415 8	0.403 1	0.285 7	0.372 0	0.263 1




图 3 各数据集消融结果可视化对比

Fig. 3 Visual comparison of ablation results on different datasets

4.5 超参分析

本文 MSRHN 中涉及到的超参主要有网络层数和多头注意力机制的头数两个。本节通过实验分析这两个超参对模型性能的影响。

4.5.1 层数影响分析

为深入探究网络层数对实验结果的影响,本文在局部时空增强图、全局交互超图以及社交关系超图这三种不同图结构中分别开展了网络层数的实验。如图 4、5 所示,局部时空增强图中,在 NYC、TKY 和 Gowalla 三个数据集上,本文 MSRHN 通过将层数设为 2 时,能够达到最佳的性能表现,这是因为 MSRHN 在此情形下可以有效地捕获 user-PoI 交互过程中存在的空间-时间相关性。当继续增加层数时,性能出现了下降的趋势,其原因很可能是由于过度平滑问题所导致的。如图 6、7 所示,在全局交互超图中,NYC 和 TKY 数据集上叠加 1 层,可以实现最佳性能。实验结果表明,MSRHN 能够有效地发现和提取高阶协同信号,进一步增加层数,性能同样会下降,原因是出现过拟合现象。但在 Gowalla 数据集上叠加 4 层,可以实现最佳性能,是因为 Gowalla 数据集包含更复杂的高阶协同信息,需要更多的网络层数来充分挖掘和利用信息。如图 8、9 所示,在社交关系超图中,NYC 和 Gowalla 数据集上,本文 MSRHN 通过叠加 4 层网络,能够实现最佳性能,而在 TKY 数据集上,叠加 2 层可达到最佳性能。实验结果表明,MSRHN 能够有效地获取社交高阶信息,同样地,当层数超出上述最佳值继续增加时,性能会

出现下降情况,原因也是受到了过度平滑的影响。




图 4 局部时空增强图层数影响(recall)

Fig. 4 Influence of layers of the local spatio-temporal enhanced graph(recall)




图 5 局部时空增强图层数影响(NDCG)

Fig. 5 Influence of layers of the local spatio-temporal enhanced graph(NDCG)




图 6 全局交互超图层数影响(recall)

Fig. 6 Influence of layers of the global interaction hypergraph(recall)




图 7 全局交互超图层数影响(NDCG)

Fig. 7 Influence of layers of the global interaction hypergraph(NDCG)




图 8 社交关系超图层数影响(recall)

Fig. 8 Influence of layers of the social relationship hypergraph(recall)

4.5.2 头数影响分析

为探索时空聚合层中多头注意力机制的头数对 MSRHN 模型的影响,本文选取四种情况的头数即 {1,2,4,8} 进行实验验证,实验结果如图 10、11 所示。从图 10、11 可以看出,本文 MSRHN 对 recall 和 NDCG 指标上的头数不敏感,在 NYC 和

TKY 数据集上使用 2 个头取得了最佳性能,在 Gowalla 数据集上使用 1 个头取得了最佳性能。随着头部数量从 2 增加到 8,三个数据集上的 recall@10 和 NDCG@10 几乎不变或微小下降。原因可能是在局部时空增强图中捕获 user-PoI 交互的空间-时间相关性时产生了过拟合。




图 9 社交关系超图层数影响(NDCG)
Fig. 9 Influence of layers of the social relationship hypergraph(NDCG)




图 10 头数影响(recall)
Fig. 10 Influence of the number of heads(recall)




图 11 头数影响(NDCG)
Fig. 11 Influence of the number of heads(NDCG)

4.6 讨论与分析

4.6.1 复杂度分析

为评估所提 MSRHN 的计算效率,本文将其与两种基于超图的次优基线方法(MSTHN 与 ASTHL)进行对比。所有实验在 NYC、TKY 和 Gowalla 数据集上采用相同的输入配置,以确保公平性。如表 8 所示,实验记录了各模型的 GPU 内存占用(GM)与训练耗时(time)。

表 8 不同模型的 GPU 内存使用与训练耗时

Tab. 8 GPU memory usage and training time of different models

method	NYC		TKY		Gowalla	
	time/s	GM/GB	time/s	GM/GB	time/s	GM/GB
MSRHN	113.47	0.26	717.90	3.25	97.51	0.15
MSTHN	35.05	0.22	161.26	3.10	25.72	0.11
ASTHL	41.08	0.23	171.17	3.16	28.64	0.13

实验结果表明,MSRHN 在内存消耗与训练时间上均高于基线模型,主要是因为:ASTHL 与 MSTHN 的核心模块均基于稀疏矩阵乘法实现,具备线性的时间复杂度与空间复杂度 $O(n)$ 。相较之下,MSRHN 所引入的社交关系超图模块具有 $O(n^2)$ 的时间复杂度。尽管通过降维技术将其空间复杂度优化至 $O(n)$,但此模块仍使 MSRHN 的整体计算负荷有一定的增加。

尽管计算复杂度更高,但 MSRHN 在推荐准确性上取得了较大提升。社交关系超图的引入使模型能够有效捕捉用户间复杂的高阶交互关系,这类关联难以通过仅依赖全局特征的线性模型充分刻画。因此,MSRHN 以可接受的计算开销为代价,换取模型表达能力与推荐精度的提升。

4.6.2 关于时间粒度选择的讨论

本文选择以“日”作为划分用户会话的基本时间单元。这一选择是基于对相对长期依赖关系的建模需求、数据特性及模型泛化能力的综合考量。

首先,本文聚焦于捕捉用户相对长期的依赖关系与稳定偏好。在 PoI 推荐场景中,用户行为通常呈现出以“日”为周期的稳定模式,能够有效反映其主导的兴趣偏好。相比之下,小时内的瞬时波动更容易受到随机因素的影响,信噪比较低,不利于识别用户相对长期的兴趣偏好。因此,以“日”为单位划分会话有助于提取更具有鲁棒性的用户行为。

其次,数据稀疏性与模型有效性的权衡。时间粒度的细化会显著加剧数据的稀疏性问题。若将会话单元从“日”缩短至“小时”,将产生大量交互项过少甚至为空的超短会话。这种稀疏性会对基于深度学习的模型的训练造成极大挑战,模型难以从过短的序列中学习有意义的上下文信息。而以“日”为单位划分,可以在保证大多数会话拥有足够交互数据的同时,有效捕获一天内的主要行为模式,是实现模型复杂度与数据有效性之间平衡的最佳选择。

综上所述,以“日”作为会话单元有助于本研究专注于建模用户的相对长期依赖关系,同时避免了由细粒度划分所引起的数据稀疏性问题,是本文在当前研究阶段中的最佳选择。

5 结束语

本文针对兴趣点推荐中社交关系的有效提取和利用,以及多图融合提升推荐性能的挑战,提出社交关系超图网络增强的多图融合兴趣点推荐方法。此方法借助局部时空增强图网络、全局交互超图网络和社交关系超图神经网络,实现对用户行为和偏好的全面捕捉。设计局部时空增强图网络,通过对时间和空间维度的精细建模,有效捕捉用户在不同时间和地点的行为变化。针对 PoI 间复杂关联特性,构建全局交互超图网络,通过超边建模多个 PoI 的协同关系,利用超图卷积捕获跨 PoI 的高阶语义联系。此外,提出社交关系超图网络,突破传统方法中成对社交关系建模的局限,利用超图卷积捕获高阶社交关系信息。最后,通过多图有效融合与预测,生成推荐结果。此方法综合考虑时空因素和社交关系信息,从而更准确地把握用户的兴趣点和行为趋势。在三个真实数据集上的实验结果表明,该方法在推荐准确性和有效性上均优于基线方法,较好地提升了兴趣点推荐方法的综合性能。

本文方法具有广阔的应用前景,尤其适用于智慧旅游平台中的个性化行程规划以及本地生活服务类平台的精准营销等场景。以一位处于旅游景区的游客为例,系统需要为其推荐可能感兴趣的 PoI。此用户的历史行为数据反映出对“精品咖啡”存在潜在偏好。在此情境下,本模型融合三大组件,为用户生成个性化 PoI 推荐列表,其协同推理过程如下:首先,局部时空图组件依据用户所处的精确时空上下文,将候选 PoI 限定于其周边步行可达的餐饮与休闲场所,优先筛选符合便利性需求的兴趣点。之后,社交关系超图组件介入,通过分析该用户所属“旅游兴趣社群”中其他用户的集体行为,发现该群体普遍对“景观视野良好的咖啡馆”给予较高评价。此类社交信号提升了具备相应特征的 PoI 的推荐权重。与此同时,全局交互超图组件引入轨迹间的全局信息,确保推荐列表能够融合景区内广受欢迎的热门目的地,有效平衡探索与利用。最终,模型综合以上信息,生成 top-K 推荐列表,其中排名第一的为“观景台咖啡厅”,符合目标用户的潜在偏好。此结果有效地融合了时空邻近性、社群偏好与全局热门,验证了模型在实际应用中的有效性与优越性。

在未来工作中,将致力于动态演化的社交关系建模,以克服静态模型的局限,精准捕捉用户社交偏好的时序变化规律。其次,将深度挖掘 PoI 的类别信息,构建基于类别的兴趣图谱来理解用户行为的高层语义动机,提升模型的泛化与解释能力。

参考文献:

- [1] Sun Lili, Zhang Yonggang, Zheng Yandong, *et al.* PLPR: towards efficient and privacy-preserving LBSNs-based PoI recommendation in cloud [C]// Proc of IEEE International Conference on Communications. Piscataway, NJ: IEEE Press, 2023: 1554-1559.
- [2] 李婉秋, 张超群, 汤卫东, 等. 面向下一个兴趣点推荐的细粒度时空多语义超图学习[J]. 计算机应用研究, 2025, 42(2): 398-405. (Li Wanqiu, Zhang Chaoqun, Tang Weidong, *et al.* Fine-grained spatiotemporal multi-semantic hypergraph learning for next point-of-interest recommendation [J]. *Application Research of Computers*, 2025, 42(2): 398-405.)
- [3] Islam M A, Mohammad M M, Sarathi Das S S, *et al.* A survey on deep learning based Point-of-Interest (PoI) recommendations [J]. *Neurocomputing*, 2022, 472: 306-325.
- [4] 刘超, 朱军. 基于序列图时空增强与地理关系的兴趣点推荐[J]. 计算机应用研究, 2025, 42(3): 755-761. (Liu Chao, Zhu Jun. Point-of-interest recommendation based on sequence graph spatiotemporal enhancement and geographic relationships [J]. *Application Research of Computers*, 2025, 42(3): 755-761.)
- [5] Xu Bin, Ge Chuanming, Zhao Wei, *et al.* A new self-adaptive hybrid Markov topic model PoI recommendation in social networks [J]. *Journal of Circuits, Systems and Computers*, 2022, 31(2): 2250039.
- [6] Li Chunshan, Li Dongmei, Zhang Zhongya, *et al.* MST-RNN: a multi-dimension spatiotemporal recurrent neural networks for recommending the next point of interest [J]. *Mathematics*, 2022, 10(11): 1838.
- [7] Mu Wenqian, Liu Jiyan, Gong Yongshun, *et al.* GeM: Gaussian embeddings with multi-hop graph transfer for next PoI recommendation [J]. *Neural Networks*, 2025, 186: 107290.
- [8] Gong Weihua, Zheng Kechen, Zhang Shubin, *et al.* Deep pairwise learning for user preferences via dual graph attention model in location-based social networks [J]. *Expert Systems with Applications*, 2023, 227: 120222.
- [9] Acharya M, Mohbey K K. Trust-aware spatial-temporal feature estimation for next PoI recommendation in location-based social networks [J]. *Social Network Analysis and Mining*, 2023, 13(1): 102.
- [10] Luo Guixun, Zhang Zhiyuan, Diao Sumeng. Empirical analysis and modelling social network user interaction behavior and time characteristics based on selection preference [J]. *Information Sciences*, 2022, 608: 1202-1220.
- [11] Lai Yantong, Su Yijun, Wei Lingwei, *et al.* Multi-view spatial-temporal enhanced hypergraph network for next PoI recommendation [M]// Wang Xin, Sapino M L, Han W S, *et al.* Database Systems for Advanced Applications. Cham: Springer, 2023: 237-252.
- [12] Li Ruichang. Joint modeling of user behaviors based on variable-order additive Markov chain for PoI recommendation [J]. *Wireless Communications and Mobile Computing*, 2021, 2021(1): 4359369.
- [13] Wang Chen, Yuan Mengting, Yang Yang, *et al.* Revisiting long- and short-term preference learning for next PoI recommendation with hierarchical LSTM [J]. *IEEE Trans on Mobile Computing*, 2024, 23(12): 12693-12705.
- [14] Wang Dongjing, Wan Feng, Yu Dongjin, *et al.* Context-and category-aware double self-attention model for next PoI recommendation [J]. *Applied Intelligence*, 2023, 53(15): 18355-18380.
- [15] Xia Qingxin, Hara T, Maekawa T, *et al.* An effective and efficient self-attention based model for next PoI recommendation [C]// Proc of IEEE International Conference on Pervasive Computing and Communications Workshops and Other Affiliated Events. Piscataway, NJ: IEEE Press, 2023: 478-483.
- [16] Song Xiaoyu, Liu Zhizhong, Meng Lingqiang, *et al.* Accurate PoI recommendation for random groups with improved graph neural networks and a multi-negotiation model [J]. *Scientific Reports*, 2025, 15(1): 7531.
- [17] Wang Liang, Wu Shu, Liu Qiang, *et al.* Bi-level graph structure learning for next PoI recommendation [J]. *IEEE Trans on Knowledge and Data Engineering*, 2024, 36(11): 5695-5708.
- [18] Rao Xuan, Chen Lisi, Liu Yong, *et al.* Graph-flashback network for next location recommendation [C]// Proc of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2022: 1463-1471.
- [19] Yan Xiaodong, Song Tengwei, Jiao Yifeng, *et al.* Spatio-temporal hypergraph learning for next PoI recommendation [C]// Proc of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2023: 403-412.
- [20] Xia Xin, Yin Hongzhi, Yu Junliang, *et al.* Self-supervised hypergraph convolutional networks for session-based recommendation [C]// Proc of AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2021: 4503-4511.
- [21] Zeng Jun, Tao Hongjin, Tang Haoran, *et al.* Global and local hypergraph learning method with semantic enhancement for PoI recommendation [J]. *Information Processing & Management*, 2025, 62(1): 103868.
- [22] Feng Yifan, You Haoxuan, Zhang Zizhao, *et al.* Hypergraph neural networks [C]// Proc of AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2019: 3558-3565.
- [23] Lai Yantong, Su Yijun, Wei Lingwei, *et al.* Adaptive spatial-temporal hypergraph fusion learning for next PoI recommendation [C]// Proc of IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway, NJ: IEEE Press, 2024: 7320-7324.
- [24] Xu Qi, Zhu Hui, Zheng Yandong, *et al.* Practical and privacy-preserving geo-social-based PoI recommendation [J]. *Journal of Information and Intelligence*, 2024, 2(2): 148-166.
- [25] Li Xiao, Sun Li, Ling Mengjie, *et al.* A survey of graph neural network based recommendation in social networks [J]. *Neurocomputing*, 2023, 549: 126441.
- [26] Li Xiaoyan, Xu Shenghua, Jiang Tao, *et al.* PoI recommendation method of neural matrix factorization integrating auxiliary attribute information [J]. *Mathematics*, 2022, 10(19): 3411.
- [27] Liu Yuwen, Qi Lianying, Liu Weiming, *et al.* GraphSAGE-based PoI recommendation via continuous-time modeling [C]// Companion Proc of ACM Web Conference. New York: ACM Press, 2024: 585-588.
- [28] Zuo Changqi, Zhang Xu, Yan Liang, *et al.* GUGEN: global user graph enhanced network for next PoI recommendation [J]. *IEEE Trans on Mobile Computing*, 2024, 23(12): 14975-14986.
- [29] 陈劲松, 孟祥武, 纪威宇, 等. 基于多维上下文感知图嵌入模型的兴趣点推荐[J]. 软件学报, 2020, 31(12): 3700-3715. (Chen Jinsong, Meng Xiangwu, Ji Weiyu, *et al.* Point-of-interest recommendation based on multi-dimensional context-aware graph embedding model [J]. *Journal of Software*, 2020, 31(12): 3700-3715.)
- [30] Dai Shaojie, Yu Yanwei, Fan Hao, *et al.* Spatio-temporal representation learning with social Tie for personalized PoI recommendation [J]. *Data Science and Engineering*, 2022, 7(1): 44-56.
- [31] Anjiri S N, Ding Derui, Song Yan, *et al.* A multiplex hypergraph attribute-based graph collaborative filtering for cold-start PoI recommendation [J]. *IEEE Trans on Big Data*, 2025, 11(5): 2401-2416.
- [32] Ashish V, Shazeer N, Parmar N, *et al.* Attention is all you need [C]// Proc of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY: Curran Associates Inc., 2017: 6000-6010.
- [33] He Xiangnan, Deng Kuan, Wang Xiang, *et al.* LightGCN: simplifying and powering graph convolution network for recommendation [C]// Proc of the 43rd International ACM SIGIR conference on research and development in Information Retrieval. New York: ACM Press, 2020: 639-648.
- [34] An Jingmin, Gao Ming, Tang Jiafu. MvStHGL: multi-view hypergraph learning with spatial-temporal periodic interests for next PoI recommendation [J]. *ACM Trans on Information Systems*, 2024, 42(6): 1-29.
- [35] Mahmood O, Mansimov E, Bonneau R, *et al.* Masked graph modeling for molecule generation [J]. *Nature Communications*, 2021, 12(1): 3156.
- [36] Yang Dingqi, Zhang Daqing, Zheng V W, *et al.* Modeling user activity preference by leveraging user spatial temporal characteristics in LBSNs [J]. *IEEE Trans on Systems, Man, and Cybernetics: Systems*, 2015, 45(1): 129-142.
- [37] Yin Hongzhi, Cui Bin, Chen Ling, *et al.* Modeling location-based user rating profiles for personalized recommendation [J]. *ACM Trans on Knowledge Discovery from Data*, 2015, 9(3): 1-41.
- [38] Zhao Pengpeng, Luo Anjing, Liu Yanchi, *et al.* Where to go next: a spatio-temporal gated network for next PoI recommendation [J]. *IEEE Trans on Knowledge and Data Engineering*, 2022, 34(5): 2512-2524.
- [39] Sun Ke, Qian Tieyun, Chen Tong, *et al.* Where to go next: modeling long- and short-term user preferences for point-of-interest recommendation [C]// Proc of AAAI Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2020: 214-221.
- [40] Qin Yifang, Wang Yifan, Sun Fang, *et al.* DisenPoI: disentangling sequential and geographical influence for point-of-interest recommendation [C]// Proc of the 16th ACM International Conference on Web Search and Data Mining. New York: ACM Press, 2023: 508-516.
- [41] Xia Lianghao, Huang Chao, Xu Yong, *et al.* Hypergraph contrastive collaborative filtering [C]// Proc of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2022: 70-79.