



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目：基于自适应边权重的图神经网络的下一个兴趣点推荐
作者：史艳翠，刘志豪，乔婧婧
DOI：10.13364/j.issn.1672-6510.20250177
收稿日期：2025-11-22
网络首发日期：2026-09-03
引用格式：史艳翠，刘志豪，乔婧婧. 基于自适应边权重的图神经网络的下一个兴趣点推荐[J/OL]. 天津科技大学学报.
<https://doi.org/10.13364/j.issn.1672-6510.20250177>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。



基于自适应边权重的图神经网络的下一个兴趣点推荐

史艳翠, 刘志豪, 乔婧婧
(天津科技大学人工智能学院, 天津 300457)

摘要: 现有的兴趣点 (point of interest, POI) 推荐方法在捕捉用户兴趣漂移以及融合多源时空信息等方面存在局限性。针对用户兴趣随时间、场景的快速演变以及地理环境变化带来的挑战, 本文提出基于自适应双图学习框架的下一个兴趣点 POI 推荐模型 (graph dual neural network with adaptive edge weighting, GDNN)。模型通过构建访问序列图和兴趣点地理图的自适应双图协同框架, 利用门控图神经网络捕捉用户行为的时序依赖性和兴趣演变轨迹, 利用图卷积网络学习 POI 间的空间邻近性和区域功能属性。其中, 双图结构显式解耦短期序列模式与长期地理偏好, 有效建模兴趣的快速演变; 自适应边权重机制则通过非线性衰减函数, 自适应建模不同区域的时空衰减特性。引入多头注意力机制融合地理与序列表征, 通过注意力权重揭示模型决策过程, 结合点击概率预测实现精准排序推荐。在 Foursquare 和 Gowalla 数据集上进行实验验证, 结果表明 GDNN 显著优于最优基线, 归一化折损累计增益@20 分别提升 8.24% 和 4.67%, 召回率 Recall@20 提升 9.20% 和 7.11%。

关键词: 推荐系统; 下一个兴趣点推荐; 自适应双图学习

中图分类号: TP391 文献标志码: A

Next POI Recommendation Based on Adaptive Edge Weight Graph Neural Network

SHI Yancui, LIU Zhihao, QIAO Jingjing

(College of Artificial Intelligence, Tianjin University of Science and Technology, Tianjin 300457, China)

Abstract: Existing point-of-interest (POI) recommendation methods still have significant limitations in capturing user interest drift and integrating multi-source spatiotemporal information. In response to the challenges posed by the rapid evolution of user interests over time and in different scenarios, as well as changes in geographical environments, this paper proposes a next POI recommendation model based on an adaptive dual graph learning framework (graph dual neural network with adaptive edge weighting, GDNN). This model utilizes a gated graph neural network to capture the temporal dependencies of user behavior and the evolution trajectory of interests by constructing an adaptive dual graph collaborative framework consisting of an access sequence graph and an interest point geographic graph; Using graph convolutional networks to learn spatial proximity and regional functional attributes between POIs. Among them, the dual graph structure explicitly decouples short-term sequence patterns from long-term geographic preferences, effectively modeling the rapid evolution of interests; The adaptive edge weighting mechanism adaptively models the spatiotemporal attenuation characteristics of different regions through a nonlinear attenuation function. In addition, a multi head attention mechanism is

收稿日期: 2025-11-22; 修回日期: 2026-05-11

基金项目: 国家自然科学基金资助项目(62377036)

作者简介: 史艳翠(1982—), 女, 河北保定人, 副教授; 通信作者: 刘志豪, 硕士研究生, 2630515196@qq.com

introduced to integrate geographic and sequence representations, revealing the decision-making process of the model through attention weights, and combining click probability prediction to achieve accurate ranking recommendations. Experimental verification was conducted on the Foursquare and Gowalla datasets, and the results showed that GDNN significantly outperformed the optimal baseline, NDCG@20 increased by 8.24% and 4.67% respectively, Recall@20 increased by 9.20% and 7.11%.

Keywords: recommendation system; next point of interest recommendation; adaptive dual graph learning

随着互联网和移动技术的发展,信息获取变得更加容易,但信息过载问题日益严重,用户难以筛选出感兴趣的内容。推荐系统作为一种有效工具,受到广泛关注,尤其是基于地理位置服务的兴起,使下一个兴趣点(point of interest, POI)推荐系统成为研究热点。这类系统通过分析用户历史行为模式,提供个性化的位置推荐,从而提升用户体验。

传统的兴趣点推荐系统主要关注于预测用户在地理位置社交网络中的下一个可能访问的地点,通常采用基于内容和序列的推荐方法^[1],通过分析用户访问的兴趣点的特征(如类别、标签等),推荐相似的兴趣点。然而,这类方法难以捕捉用户偏好的复杂时序依赖与场景敏感性^[2]。Top 模型^[3]利用知识图谱嵌入技术结合时空数据,学习 POI 的上下文感知表示。通过考虑区域的功能属性,Top 模型能够更好地捕捉用户在特定区域的偏好,提高推荐的个性化程度。尽管该模型考虑了 POI 的多功能性,但对于快速变化的用户偏好和城市环境仍存在局限性。SCGM 模型^[4]提出一种新的用户相似度计算方法,结合类别差异和 POI 潜在向量,计算用户间的相似度,提供用户签到行为的分析,并建模 POI 及区域的多功能语义,从而给出可解释的推荐;但仍需进一步在建模复杂时空交互、实时性、多源数据融合以及模型泛化能力等方面研究和改进。虽然上述方法对不同的问题都有所改善,但是下一个兴趣点推荐算法仍然存在一些局限:用户的兴趣和签到行为可能因个人生活事件、季节、社会事件等因素而迅速变化。

针对上述问题,本文提出了一种基于自适应双图学习框架的下一个兴趣点推荐模型,通过端到端的权重学习和多头注意力融合机制,提升模型对用户兴趣演变和地理分布变化的自适应能力。首先,提出增强的双图协同学习框架,构建访问序列图和兴趣点地理图,分别捕捉用户行为的时序依赖和 POI 的空间关联。模型能够独立学习序列模式和地理偏好,并通过协同优化提供更精准的推荐。其次,设计自适应边权重学习机制,结合可学习的衰减率参数和多层感知机

(MLP)实现边权重的端到端学习。最后,引入多头注意力机制融合序列和地理特征,通过多个表示子空间捕捉两种特征间的复杂交互关系。

1 相关工作

1.1 基于位置的下一个兴趣点推荐

用户在选择下一个访问的兴趣点时,往往倾向于选择距离当前位置较近的地方。这种现象被称为地理亲近性^[5],地理亲近性可以帮助系统更准确地预测用户的下一步行动,是推荐算法设计中必须考虑的关键因素。马尔可夫链^[6]是一种统计模型,它假设系统的下一个状态只依赖于当前状态,而与之前的历史状态无关。在基于位置的推荐系统中,马尔可夫链被用来预测用户的移动序列。每个 POI 可以被视为马尔可夫链中的一个状态,用户在不同 POI 间的转移被视为状态转移。通过分析用户的历史签到数据,可以学习到状态转移的概率分布,进而预测用户接下来可能访问的 POI。

1.2 基于 GNN 的下一个兴趣点推荐

随着深度学习技术的发展,基于图神经网络(GNN)的推荐模型因其在捕捉时空特征及其复杂关系方面的能力而受到关注^[7]。GNN 能够为图中的每个节点生成嵌入向量^[8],用于节点分类、链接预测和图聚类等任务。在推荐系统中,GNN 常以用户-兴趣点交互图的形式表示,有效捕捉节点间复杂的高阶关系,更准确地建模用户偏好^[9]。Hajisafi 等^[10]提出动态图构建方法(BysGNN),能够根据输入数据的变化动态调整图的结构。这种方法不仅考虑了时间序列的动态变化,还结合了地理空间和语义信息,使图结构更加灵活和准确;但是,BysGNN 在构建动态图时需要考虑多种上下文信息,模型的计算复杂度较高。Yin 等^[11]提出基于序列的动态邻域图(SNPM),能够根据用户的前序轨迹动态选择当前 POI 的邻域节点。该模型的构建依赖用户的历史轨迹,但用户的历史轨迹并不能都反映当前的上下文信息。Wang 等^[12]

提出显式考虑用户的动态行为意图的模型 (DyHGN), 通过构建动态感知的异构图, 该模型能够捕捉用户在不同时间段内的行为变化。

然而, 现有基于 GNN 的方法仍普遍存在两大局限: 第一, 图的边权重多依赖预设的启发式函数 (如距离衰减), 缺乏自适应学习能力; 第二, 序列与地理特征的融合方式较为简单, 难以捕捉复杂交互。这为本文的自适应图学习与多头注意力融合机制提供改进空间。

1.3 自适应图学习在 POI 推荐中的应用

现有基于 GNN 的 POI 推荐模型通常依赖预定义的静态图结构 (如基于固定距离衰减函数构建地理图), 难以适应用户行为与空间关系的非线性变化。因此, 近期研究开始探索自适应图学习技术^[13], 旨在从数据中端到端优化图拓扑或边权重。例如, 通过可学习相似度重构邻接矩阵, 以发现潜在关联^[14]; 设计神经网络替代手工衰减函数, 实现更灵活的权重分配。然而, 现有方法在边权重的自适应学习方面仍存在明显不足: DisenPOI^[15]的地理边权重仍采用固定的指数衰减函数, 无法自适应调整衰减率; DyHGN^[12]虽引入时空上下文感知, 但其图结构更新依赖历史行为统计, 缺乏对权重函数本身的端到端学习能力。

1.4 多特征融合策略

在 POI 推荐中, 有效融合序列模式与地理偏好是提升预测性能的关键。早期方法通常采用特征拼接或加权求和等简单策略, 难以捕捉两类特征间复杂的交互关系。近年来, 注意力机制因其能够分配特征重要性而被广泛采用。GETNext^[16]通过 Transformer 编码器联合轨迹序列与转移图信息; STAN^[17]利用时空注意力机制建模 POI 间的转移依赖。然而, 现有融合策略仍存在局限: 多数方法将序列与地理特征视为单一向量进行融合, 忽略了二者在不同语义子空间中的差异化关联; DisenPOI 虽然尝试通过对比学习解耦地理

与序列影响, 但其融合过程间接且不可解释, 解耦目标侧重于分离表示空间, 未能显式建模用户兴趣的演化轨迹; DyHGN 则未设计专门的特征融合模块, 限制了多源信息的协同利用。

2 算法描述

2.1 问题定义

用户集合表示为 $U=\{u_1, u_2, \dots, u_i, \dots, u_M\}$, M 表示用户的数量, 将兴趣点的集合表示为 $P=\{p_1, p_2, \dots, p_i, \dots, p_N\}$, N 表示兴趣点的数量, 将用户的访问序列定义为 $S=[p_1, p_2, \dots, p_i, \dots, p_p]$, 将用户访问序列 S 中每个兴趣点 p 的位置定义为 l , 则位置信息可以表示为 $L=\{l_1, l_2, \dots, l_i, \dots, l_p\}$ 。

模型的任务是基于用户访问兴趣点的情况提取用户的访问偏好, 为该用户提供下一个兴趣点的推荐列表。模型输入用户的行为数据, 包括用户-兴趣点的交互、用户访问兴趣点的顺序、兴趣点的信息 (兴趣点的类别、地理位置)。模型为用户输出排序后的兴趣点推荐列表以及用户对兴趣点的点击概率 $Y=\{y_1, y_2, \dots, y_i, \dots, y_k\}$, 其中 Y 是推荐列表, y_i 存储对应的第 i 个推荐的兴趣点和对应的分数。将 Y 中分数最高的前 k 个兴趣点作为候选下一个兴趣点推荐。

2.2 模型概述

本研究提出基于自适应双图学习框架的下一个兴趣点推荐模型 (graph dual neural network with adaptive edge weighting, GDNN), 旨在通过自适应权重学习和多头注意力融合机制提升推荐系统的准确性和可解释性。模型整体框架由双图协同学习、自适应权重优化和多头注意力融合组成, 如图 1 所示。




图 1 模型整体框架

Fig.1 Overall framework of the model

本文模型设计的核心思想是构建访问序列图与兴趣点地理图，分别建模用户行为的时序依赖性和 POI 间的地理关联性；并通过自适应边权重机制优化图中边的重要性，最终通过多头注意力机制融合多源信息，生成个性化推荐结果。

2.3 图神经网络部分

基于兴趣点间的地理关系和用户签到历史中的顺序关系进行下一个兴趣点的预测，构建两个不同的图分别满足这两个目的。

2.3.1 访问序列图

用户签到行为具有明显的时序依赖。给定一个用户 u 及其签到历史 S_u ，构造有向图 $G_{u,s} = \{V_{u,s}, E_{u,s}\}$ ，顺序图中的每个节点代表一个兴趣点，图中的有向边表示用户访问 POI 的顺序。 $V_{u,s}$ 代表节点集合， $E_{u,s}$ 代表边的集合。对于每个用户，根据他们的历史访问记录，将访问的 POI 序列化，即如果用户在访问 POI a 后访问 POI b ，则在 a 和 b 间有一条从 a 指向 b 的边。每个用户的访问历史（访问顺序信息）都被表示为一个序列图，计算图中每个兴趣点的节点影响系数 δ 。该系数用于调制邻居节点对当前节点的有效影响强度，而非直接作为节点表示参与学习。节点影响系数由访问频率权重和时间权重两部分组成，计算公式为

$$\delta_a = \alpha_a \cdot f_a + (1 - \alpha_a) \cdot t_a \quad (1)$$

式中： δ_a 表示节点 a 的影响系数， α_a 表示自适应融合权重， f_a 表示访问频率权重， t_a 表示时间权重。

为避免人为设定融合权重带来的偏置，本文将不设 α_a 为固定超参数，而是通过节点行为特征自适应计算。将 f_a 和 t_a 作为输入，通过多层感知机（MLP）学习其到融合权重的映射关系，为：

$$\alpha_a = \sigma(\text{MLP}_{\theta}(f_a, t_a)) \quad (2)$$

式中： σ 为 Sigmoid 激活函数，使 $\alpha_a \in (0, 1)$ 。 f_a 为当前

图中该兴趣点的被访问次数与所有兴趣点的被访问次数之比，采用对数变换进行调整，用来减少数据的偏态和异方差性。

$$f_a = \log(1 + \frac{n_a}{C}) \quad (3)$$

式中： n_a 表示该兴趣点的被访问次数， C 表示当前序列图中所有兴趣点的累计访问次数。

t_a 的计算采用自适应边权重学习机制，通过 MLP 端到端地学习时间间隔到边权重的映射关系，计算公式为

$$t_a = \sigma(\text{MLP}_{\theta}(\Delta t_a)) \quad (4)$$

式中： Δt_a 表示该节点的访问时间与当前时间的差值。

该机制通过 MLP 直接学习时间/距离到权重的非线性映射，无需引入衰减率参数。MLP 为多层感知机，本文采用两层结构，隐藏层维度为 16，激活函数为 ReLU， σ 为 Sigmoid 激活函数，用于将输出规范化到 (0,1)。通过数据驱动方式替代传统固定衰减函数，该权重函数采用全局共享参数，而非为每个用户单独建模。这一设计基于一个关键观察：用户兴趣演变更多由场景驱动的时空模式（如工作日通勤 vs 周末休闲）所主导，而非依赖于高度个性化的距离/时间衰减函数。该全局权重被应用于 GNN 的消息传递过程中，与具体的 POI 嵌入相结合，从而在聚合后的节点表示中实现上下文感知的自适应效果。

该机制的设计优势：（1）全局共享性。模型参数在所有用户与 POI 间共享，有效捕捉共性的时空演化模式。（2）函数级自适应。MLP 学习从距离（或时间间隔）到权重的非线性映射。相比固定的指数衰减函数，该机制能捕捉更复杂的关系模式。（3）可扩展性：尽管当前实现仅以 Δt_a 为输入，但该框架支持将节点嵌入、边类型等上下文信息融入 MLP 输入，

从而实现相同距离在不同场景下的差异化加权, 为未来增强模型表达能力提供灵活路径。

在门控图神经网络 (GGNN) 中, 节点直接接收邻居节点的隐藏状态作为传播信息, 然而在 POI 序列中, 不同邻居对当前节点的影响强度存在显著差异。为增强模型对邻居重要性的刻画能力, 对其消息函数进行扩展。在标准 GGNN 的邻居聚合阶段, 引入自适应边权重与共享变换矩阵, 对邻居节点的隐藏状态进行调制。对于节点 a , 其邻居节点集合为 $N(a)$, 节点在第 l 层的隐藏状态为 $\mathbf{h}_a^{(l)}$ 。对于邻居节点 b , 其节点影响系数为 δ_b , 自适应学习的边权为 η_{ab} , 二者同时构成有效传播权重, 为

$$\tilde{\rho}_{ba} = \eta_{ba} \cdot \delta_b \quad (5)$$

式中: $\tilde{\rho}_{ba}$ 表示邻居节点 b 向 a 传播时的有效权重; δ_b 描述兴趣点自身的活跃程度与时间新鲜度; 而 η_{ba} 则刻画从位置 b 转移至位置 a 的时序转移强度。二者分别建模节点属性与转移关系, 在消息传播阶段共同调制邻居影响。邻居节点 b 向节点 a 的传播消息定义为 $\mathbf{M}_{ba}^{(l)}$, 为

$$\mathbf{M}_{ba}^{(l)} = \tilde{\rho}_{ba} \mathbf{W}_m \mathbf{h}_b^{(l-1)} \quad (6)$$

式中: $\mathbf{W}_m$ 为共享变换矩阵, $\mathbf{h}_b^{(l-1)}$ 为节点 b 在 $l-1$ 层的隐藏状态向量。节点 a 聚合所有邻居信息得到输入信息 $\mathbf{A}_a^{(l)}$, 为

$$\mathbf{A}_a^{(l)} = \sum_{b \in N(a)} \mathbf{M}_{ba}^{(l)} \quad (7)$$

式中: $N(a)$ 表示节点 a 的邻居节点集合。与直接聚合邻居状态的方式相比, 该机制在传播前对邻居信息进行加权映射, 使模型能够区分不同访问路径对当前兴趣点的影响强度。用户的访问序列不仅包含他对兴趣点的偏好信息, 还包含他的兴趣演变历史, 这隐含了他对下一个兴趣点的访问倾向^[18]。

采用 GGNN 充分利用图中的顺序信息^[19]。序列图中的每个节点 a 的初始隐藏状态表示为 $\mathbf{h}_a^0 = \mathbf{e}_a$ 。在第 l 层, 节点 a 从其所有邻居节点 b 接收消息 $\mathbf{A}_a^{(l)}$ 。节点状态更新的公式为:

$$\mathbf{z}_a^{(l)} = \sigma(\mathbf{W}_z \mathbf{A}_a^{(l)} + \mathbf{U}_z \mathbf{h}_a^{(l-1)}) \quad (8)$$

$$\mathbf{r}_a^{(l)} = \sigma(\mathbf{W}_r \mathbf{A}_a^{(l)} + \mathbf{U}_r \mathbf{h}_a^{(l-1)}) \quad (9)$$

$$\tilde{\mathbf{h}}_a^{(l)} = \tanh(\mathbf{W}_h \mathbf{A}_a^{(l)} + \mathbf{U}_h (\mathbf{r}_a^{(l)} \odot \mathbf{h}_a^{(l-1)})) \quad (10)$$

$$\mathbf{h}_a^{(l)} = (1 - \mathbf{z}_a^{(l)}) \odot \mathbf{h}_a^{(l-1)} + \mathbf{z}_a^{(l)} \odot \tilde{\mathbf{h}}_a^{(l)} \quad (11)$$

式中: $\mathbf{z}_a^{(l)}$ 和 $\mathbf{r}_a^{(l)}$ 分别为更新门和重置门, 控制隐藏状态更新^[20]; $\mathbf{W}_z$ 、 $\mathbf{U}_z$ 、 $\mathbf{W}_r$ 、 $\mathbf{U}_r$ 、 $\mathbf{W}_h$ 、 $\mathbf{U}_h$ 为可学习权重矩阵; σ 为 sigmoid 激活函数; $\tanh$ 是双曲正切激活函数。根据更新门 $\mathbf{z}_a^{(l)}$ 更新节点 a 的隐藏状态。如果 $\mathbf{z}_a^{(l)}$ 接近 1, 那么新的隐藏状态将更多地依赖于候选隐藏状态 $\tilde{\mathbf{h}}_a^{(l)}$; 如果 $\mathbf{z}_a^{(l)}$ 接近 0, 那么新的隐藏状态将更多地保留上一层的隐藏状态 $\mathbf{h}_a^{(l-1)}$ 。

将所有 POI 的最终隐藏状态堆叠成矩阵 $\mathbf{H}^{(L)} = [\mathbf{h}_1^{(L)}, \dots, \mathbf{h}_n^{(L)}]^\top \in \mathbb{R}^{n \times d}$, 代表序列图的编码^[21]。该矩阵作为序列表征, 输入至后续的多头注意力融合机制。这一过程有效捕捉了用户访问 POI 的顺序依赖性, 为预测提供了关键的序列信息, 是模型学习序列特征的核心部分。

2.3.2 兴趣点地理图

用户下一个访问的 POI 选择受地理邻近性显著影响, 但不同区域的功能属性 (如商业区与住宅区) 导致距离-影响力关系高度非线性, 因此构建兴趣点地理图。兴趣点地理图是基于 POIs 间的地理空间关系构建的无向图 G_G 。这个图用于捕捉 POIs 间的地理邻近性^[22]。图中的每个节点代表一个 POI, 而边的构建则基于 POI 间的实际地理距离^[23]。两个兴趣点 a 和 b 间的距离 d_{ab} 采用哈弗赛因公式^[24]计算, 两个兴趣点间的边使用自适应边权重学习机制计算边的距离权重 q_{ab} , 为:

$$q_{ab} = \sigma(\text{MLP}_\theta(d_{ab})) \quad (12)$$

这种权重的定义方式使得距离越近的两个 POI 间边的权重越大, 从而更好地反映了地理邻近性对用户行为的影响; 融合类别相似度形成最终权重。此外, 为了增强地理图对 POI 功能属性的建模能力, 引入可学习的类别嵌入层^[25]。对于每个 POI 类别, 模型学习低维稠密向量表示, 通过加权融合的方式, 将类别语义信息注入 POI 的地理嵌入中, 为

$$\mathbf{g}_a = \mathbf{p}_a + \beta \mathbf{c}_a \quad (13)$$

式中: $\mathbf{g}_a$ 为 POI 融合类别语义后的地理表示, $\mathbf{p}_a$ 为该 POI 的基础地理嵌入向量, $\mathbf{c}_a$ 为该 POI 所属类别的嵌入向量, β 为融合权重 (实验中设为 0.1)。这种端到端学习的方式使类别表示能够与推荐任务直接相关, 避免了预训练方法对外部语料的依赖。在考

虑距离因素的基础上,地理图中的边权重进一步融入类别相似度信息。对于两个 POI a 和 b , 计算其类别嵌入的余弦相似度作为额外的权重因子 s_{ab} 。由于余弦相似度取值范围为 $[-1,1]$, 而边权重需为非负值, 采用 $\max(0, \cdot)$ 截断以保证 $s_{ab} \geq 0$, 即

$$s_{ab} = \max(0, \cos(c_a, c_b)) \quad (14)$$

考虑到距离权重 $q_{ab} \in (0,1]$ 与类别相似度 $s_{ab} \in [0,1]$ 的量级虽然相近, 但物理意义不同, 直接相加可能破坏权重的合理性。为此, 采用可学习的加权融合策略, 最终边权重为

$$w_{ab} = q_{ab} \cdot \gamma + (1 - \gamma) \cdot s_{ab} \quad (15)$$

式中: w_{ab} 表示兴趣点 a 和 b 之间的最终边权重; $\gamma \in [0,1]$ 为可学习参数, 通过端到端训练自动优化, 以自适应平衡地理距离与类别语义的相对重要性。

地理图传播层旨在利用图结构更新每个 POI 的表示, 节点 v 在第 l 层的隐藏状态 $h_v^{(l)}$ 是其所有邻居节点 u 发送的消息的总和, 然后通过 LeakyReLU 激活函数进行非线性变换, 为

$$m_{v \leftarrow u}^{(l)} = \frac{w_{uv}}{\sqrt{|N(u)||N(v)|}} (W_1 h_u^{(l-1)} + W_2 h_v^{(l-1)}) \quad (16)$$

$$h_v^{(l)} = \text{LeakyReLU} \left(\sum_{u \in N(v)} m_{v \leftarrow u}^{(l)} \right) \quad (17)$$

$$h_v^{(l)} = \text{LeakyReLU} (W_1 h_v^{(l-1)} + \sum_{u \in N(v)} \frac{w_{uv}}{\sqrt{|N(u)||N(v)|}} W_2 h_u^{(l-1)}) \quad (18)$$

式中: $m_{v \leftarrow u}^{(l)}$ 表示第 l 层中邻居节点 u 向节点 v 传递的消息向量; w_{uv} 表示兴趣点 u 与 v 之间的最终边权重; $N(u)$ 和 $N(v)$ 分别表示节点 u 和节点 v 的邻居集合; W_1 和 W_2 为可学习权重矩阵; $h_u^{(l-1)}$ 和 $h_v^{(l-1)}$ 分别表示节点 u 和节点 v 在 $l-1$ 层的隐藏状态向量。在经过 m 层的图卷积网络 (GCN) 传播后, 所有节点的最终隐藏状态被堆叠成矩阵 $Z^{(m)} = [z_1^{(m)}, \dots, z_n^{(m)}]^T \in \mathbb{R}^{n \times d}$, 代表地理图的编码。该矩阵作为地理表征, 输入至后续的多头注意力融合机制。这些公式共同定义了如何在地理图上使用 GNN 来更新节点的表示。通过这种更新机制, 模型能够捕捉 POIs 间的地理邻近性, 从而为模型预测提供地理信息。地理图的传播层是模型中实现地理特征学习的关键部分。

在 GDNN 模型的最终实现中, 所有图结构中的边权重计算 (包括序列图的时间间隔权重、地理图的

距离权重) 均统一通过自适应机制生成。类别相似度 α 作为补充项与自适应权重融合。

2.4 多头注意力融合机制

为了更有效地融合地理和序列两种特征表示, 设计一种多头注意力融合机制。给定用户 u 的历史访问序列 S_u , 其序列特征表示 h_s^u 和地理特征表示 h_g^u 分别通过对序列图编码矩阵 $H^{(L)}$ 和 $Z^{(K)}$ 中对应 POI 的行向量进行平均池化得到。对于用户 u 的序列特征表示 h_s^u 和地理特征表示 h_g^u , 多头注意力机制首先将它们投影到 H 个不同的表示子空间。对于第 i 个注意力头 ($i \in [1, H]$), 计算查询 (Query)、键 (Key) 和值 (Value) 矩阵, 公式为

$$Q_i = W_i^Q h_s^u \quad (19)$$

$$K_i = W_i^K [h_s^u; h_g^u] \quad (20)$$

$$V_i = W_i^V [h_s^u; h_g^u] \quad (21)$$

式中: W_i^Q 、 W_i^K 、 W_i^V 为可学习的投影矩阵, $[\cdot]$ 表示特征堆叠操作。计算第 i 个头的注意力分数和输出, 为

$$\mu_i = \text{softmax} \left(\frac{Q_i K_i^T}{\sqrt{d_k}} \right) \quad (22)$$

$$o_i = \mu_i V_i \quad (23)$$

式中: d_k 为键向量的维度, 除以 $\sqrt{d_k}$ 是为了防止点积值过大导致梯度消失; o_i 表示第 i 个注意力头的输出向量。注意力权重 $\mu_i \in \mathbb{R}^{(1 \times 2)}$ 表示在融合过程中对序列和地理特征的关注重度。

最终, 将所有注意力头的输出拼接并通过线性变换得到融合表示 h_f^u , 为:

$$h_f^u = W^O [o_1; o_2; \dots; o_H] \quad (24)$$

式中: W^O 为输出投影矩阵。 h_f^u 编码了用户在当前上下文中的综合意图, 用于计算与候选 POI 的匹配得分。这种多头机制使得模型能够同时关注序列和地理特征的不同方面, 捕捉更丰富的特征交互模式。

多头注意力融合机制的优势: (1) 表达能力强。多个注意力头可以从不同角度捕捉特征交互, 相比单一注意力更加灵活和全面。(2) 上下文自适应。对于不同用户和不同推荐场景, 注意力权重 μ_i 会根据上下文调整。例如, 对于短距离移动, 地理特征的权重可能更高; 对于长距离移动, 序列模式的权重可能更高。(3) 可解释性强。通过分析注意力权重 μ_i 的分布, 可以揭示模型在不同场景下对序列和地理特征的依赖程度, 为推荐结果提供可解释性支撑。

3 算法设计

3.1 综合上下文表示

根据提出的图神经网络和软注意力机制, 模型从海量的用户行为数据和兴趣点特征中提取关键信息, 并构建精准的用户偏好和兴趣点特征表示。在预测阶段, 将所有复杂的处理和分析转化为实际的推荐结果, 为用户提供高度个性化、具有精准前瞻性的下一个兴趣点推荐列表, 从而显著提升用户体验和满意度。

地理上下文表示 $\mathbf{h}_g^u$ 捕捉用户访问兴趣点的地理位置特征, 反映用户对特定区域的偏好; 序列上下文表示 $\mathbf{h}_s^u$ 则体现用户访问兴趣点的时间顺序特征, 揭示用户兴趣的演变趋势。综合的用户上下文表示 $\mathbf{h}_u$ 能够同时包含空间和时间两个维度的信息, 为后续的预测提供更全面、更准确的用户偏好特征, 从而提高推荐的准确性和相关性。

3.2 预测函数

对于每个目标兴趣点 p_j , 将其嵌入向量 $\mathbf{e}_{p_j}$ 与经多头注意力融合得到的用户上下文表示 $\mathbf{h}_u$ 进行交互, 计算用户对目标兴趣点的点击概率。通过计算两者的点积并经过激活函数实现。点击概率的计算公式为

$$y_{u,p_j} = \sigma(\mathbf{h}_u^T \mathbf{e}_{p_j} + b) \quad (25)$$

式中: y_{u,p_j} 表示用户 u 访问候选兴趣点 p_j 的预测概率;

b 为偏置项, 用于调整模型的输出基线; σ 为 sigmoid 函数, 用于将输出值映射到 $[0,1]$ 范围内, 表示用户点击目标兴趣点的概率。点击概率的计算是模型预测阶段的核心步骤, 直接影响最终推荐列表的质量和相关性。

3.3 排序和推荐

在完成对所有兴趣点点击概率的计算后, 模型进入排序和推荐阶段。点击概率值综合了用户的行为特征和兴趣点的特征, 是模型对用户偏好的精准量化。将所有兴趣点的点击概率按照从高到低的顺序进行排序, 选择概率最高的前 K 个兴趣点作为推荐列表。根据用户 u 对各个兴趣点的点击概率, 生成高度个性化的推荐列表 Y_u , 为

$$Y_u = \text{Top-}K(\{y_{u,p_j} | p_j \in P\}) \quad (26)$$

式中: Top- K 为选取概率值最大的前 K 个兴趣点, K 为推荐列表长度。通过这种方式, 模型能够有效地将复杂的用户行为和兴趣点特征转化为直观的推荐结果, 不仅确保了推荐结果的相关性和个性化, 还提高了推荐系统的实用性和用户体验。

4 实验与结果分析

4.1 数据集及预处理

模型在两个广泛使用的真实世界数据集 (Gowalla 和 Foursquare) 上进行训练和评估。Gowalla 数据集包括 2009 年 2 月至 2010 年 10 月的用户签到数据, Foursquare 数据集收集了 2012 年 4 月至 2014 年 1 月的数据。在这两个数据集中, 签到数据由用户 ID、兴趣点 ID、经纬度和时间戳组成。在数据集的预处理阶段, 通过删除签到少于 10 个 POI 的不活跃用户和少于 10 个用户访问的 POI, 减轻了交互不足的用户和 POI 的影响。然后, 以 8:2 的比例将处理后的数据划分为两个部分, 分别用作训练集和测试集。预处理后的数据集统计信息见表 1。

表 1 预处理后的数据集统计信息

Tab. 1 Statistical information of experiment datasets

数据集	用户	兴趣点	签到
Gowalla	24731	28492	1194856
Foursquare	18652	32486	1276891

4.2 评价指标

使用归一化折损累计增益 $\text{NDCG}@k$ 和召回率 $\text{Recall}@k$ 作为模型的评价指标, 用于衡量排序结果的质量。 $\text{NDCG}@k$ 表示在推荐的前 k 个 POI 中真实访问的 POI 的比率, 该指标数值取多次实验得到的平均值, k 表示推荐给用户的 POI 个数, 计算公式为

$$\text{DCG}_k = \sum_{i=1}^k \frac{2^{r_i} - 1}{\log_2(i+1)} \quad (27)$$

$$\text{IDCG}_k = \sum_{i=1}^k \frac{2^{r_i^*} - 1}{\log_2(i+1)} \quad (28)$$

$$\text{NDCG}_k = \frac{\text{DCG}_k}{\text{IDCG}_k} \quad (29)$$

式中: r_i 表示第 i 个结果的相关性分数, 一般取 0 或 1, 也可以是多级相关的数值, 如 0、1、2、3、4 等, k 表示考虑的前 k 个结果。 r_i^* 表示前 k 个最相关 POI 的

理想排序。 $\text{Recall}@k$ 关注推荐的前 k 个物品中有多少是用户实际感兴趣的。

4.3 实验设置

实验环境: NVIDIA GeForce RTX 3090, 采用 Linux 操作系统, 使用 Python 3.8.20 及 PyTorch 1.11.0 和 CUDA 11.3 学习框架实现。在通过 RotatE 构造 POI 转移图时, 为每个 POI 选择 100 个邻居。在使用谱聚类特征选择进行 POI 聚类时, 选择 20 个最小特征值和对应的特征向量, 在 SDNG 中设置所选相邻节点的个数 $\omega=10$ 。

4.4 超参数实验

4.4.1 嵌入维度

在 Foursquare 和 Gowalla 数据集上测试不同嵌入维度 (d) 对模型性能的影响, 结果如图 2 所示。随着嵌入维度的增加, 模型性能先提升后趋于稳定或略有下降。在嵌入维度为 96 时, 两个数据集的性能达到较高水平。因此, 嵌入维度设置为 96。




图 2 嵌入维度 d 敏感性实验

Fig. 2 Sensitivity experiment of embedding dimension d

4.4.2 图卷积层数

在 Foursquare 和 Gowalla 数据集上测试不同图卷积层数 (m) 对模型性能的影响, 结果如图 3 所示。随着层数增加, 模型性能呈现先上升后下降的趋势。当 $m=2$ 时, Foursquare 与 Gowalla 数据集上的 NDCG@20 均达到峰值 (0.0856 vs 0.0853), 之后则出现明显下滑。这说明两层图卷积已足以捕获 POI 之间的二阶邻近关系。因此, 图卷积层数设为 2。




图 3 图卷积层数 m 敏感性实验

Fig. 3 Sensitivity experiment of graph convolutional layer number m

4.4.3 多头注意力头数

在 Foursquare 和 Gowalla 数据集上测试不同多头注意力头数 (h) 对模型性能的影响, 结果如图 4 所示。随着多头注意力头数的增加, 模型性能先有所提升, 达到峰值后逐渐下降。在两个数据集上, 当 $h=2$ 时, 模型的 NDCG@20 达到最高值 (Foursquare 为 0.0856, Gowalla 为 0.0853), 表明适当的多头注意力头数能够增强模型对不同兴趣维度的捕捉能力。因此, 将多头注意力头数设置为 2。




图 4 多头注意力头数 h 敏感性实验

Fig. 4 Multi-head attention head number h sensitivity experiment

4.4.4 学习率

在 Foursquare 和 Gowalla 数据集上测试不同学习率 (l) 对模型性能的影响, 结果如图 5 所示。当学习率为 0.001 时, 模型在两个数据集上的 NDCG@20 达到最高 (Foursquare 为 0.0856, Gowalla 为 0.0853), 说明该学习率能够较好地平衡模型的收敛速度和稳定性。因此, 将学习率设置为 0.001。




图 5 学习率 / 敏感性实验

Fig. 5 Sensitivity experiment of learning rate /

4.5 基线模型

为了检验 GDNN 方法的有效性, 选择以下基线模型进行比较, 实验结果如图 6 和图 7 所示。

GNN-POI^[26]: 一种利用图神经网络学习图空间结构, 结合双向长短期记忆, 模拟用户连续签到行为, 获取地理和时间特征的模型。

GPR^[27]: 一种基于图神经网络的地理潜力表示模型, 使用图自编码器来训练传入和传出的影响, 使用训练好的地理潜力表示估计用户的偏好。


LightGCN^[28]: 一种图卷积网络模型, 它去除了特征变换和非线性激活设计, 简化了 GCN, 更适合推荐任务的协同过滤。

GETNext^[16]: 一个编码器-解码器框架, 利用用户轨迹图和 POI 转移概率图进行下一个 POI 推荐。


STAN^[17]: 基于注意力的方法明确地利用签到的时空信息捕获 POI 间的相关性。

DisenPOI^[15]: 基于双路径图神经网络的模型。

DyHGN^[12]: 动态异构图神经网络模型。




(a) Foursquare 数据集




(b) Gowalla 数据集

图 6 GDNN 与基线模型的 NDCG 性能比较

Fig. 6 Comparison of NDCG performance between GDNN and baseline models



(a) Foursquare 数据集



(b) Gowalla 数据集

图 7 GDNN 与基线模型的 Recall 性能比较

Fig. 7 Comparison of Recall performance between GDNN and baseline models

与基线模型相比, 本文 GDNN 模型在 Foursquare 和 Gowalla 两个数据集上的评价指标均有明显提升, 表明其在推荐准确性和排名质量方面具有优势。在 Foursquare 数据集上, 与最优基线模型相比, NDCG@20 和 Recall@20 指标分别提升 8.24% 和 9.2%。在 Gowalla 数据集上, NDCG@20 和 Recall@20 指标分别提升 4.67% 和 7.11%。

这些实验结果显示本文方法优于其他基线模型。

本文模型的性能高于其他模型的原因包括以下几个方面: GDNN 模型构建了访问序列图和兴趣点地理图的双图协同框架,使模型能够同时从时间和空间两个维度对用户行为和兴趣点特征进行建模。与现有双图方法(如 DisenPOI)不同, GDNN 引入自适应图结构优化机制,能够调整访问序列图和兴趣点地理图的边权重与拓扑结构。在访问序列图的构建中, GDNN 模型对图的节点和边进行加权处理,综合考虑访问频率和时间因素,通过计算访问频率权重和时间权重并进行调整,能够更精准地衡量兴趣点在用户行为序列中的重要性和时效性。

表 2 在数据集 Foursquare 和 Gowalla 上变体与整体模型对比结果

Tab. 2 Comparison results of variants and overall models on the Foursquare and Gowalla dataset

模型	Foursquare 数据集				Gowalla 数据集			
	NDCG@10	NDCG@20	Recall@10	Recall@20	NDCG@10	NDCG@20	Recall@10	Recall@20
GDNN-L	0.0624	0.0716	0.0934	0.1354	0.0613	0.0703	0.0913	0.1312
GDNN-W	0.0662	0.0758	0.0978	0.1421	0.0658	0.0748	0.0965	0.1392
GDNN-S	0.0681	0.0783	0.1012	0.1486	0.0674	0.0776	0.0994	0.1447
GDNN-T	0.0715	0.0812	0.1053	0.1553	0.0705	0.0804	0.1021	0.1526
GDNN	0.0763	0.0856	0.1098	0.1796	0.0772	0.0853	0.1047	0.1703

在两个数据集上,完整的 GDNN 模型在所有评价指标上均显著优于各个变体。对比 GDNN-L 与 GDNN-W,在 Foursquare 上,NDCG@20 提升 5.87%, Recall@20 提升 4.95%;在 Gowalla 上,NDCG@20 提升 6.40%, Recall@20 提升 6.10%。对比 GDNN-T 与 GDNN-W,在引入自适应权重的基础上增加注意力,Foursquare 上 NDCG@20 提升 7.12%, Recall@20 提升 9.29%;Gowalla 上 NDCG@20 提升 7.49%, Recall@20 提升 9.62%,说明其能有效建模序列图与地理图的互补关系。在 Foursquare 上, GDNN-S 相比 GDNN-L 使 NDCG@20 提升 9.39%, Recall@20 提升 9.75%;在 Gowalla 上,NDCG@20 提升 10.38%, Recall@20 提升 10.29%,POI 类别语义能同时有效提升排序准确性与推荐覆盖能力。综上所述,类别嵌入提供强语义先验,自适应权重构建高质量图结构,多头注意力实现深度特征交互,使模型性能全面提升。

5 结语

本文提出基于自适应双图学习的下一个兴趣点推荐模型(GDNN),旨在解决现有方法在捕捉用户

4.6 消融实验

采用增量式方法,从基础双图 GNN 模型出发,逐步引入核心组件,以更清晰地评估各模块的独立贡献与协同效应。GDNN-L 为基础双图 GNN,采用固定指数衰减、简单拼接融合、无类别嵌入。GDNN-W 在 GDNN-L 基础上仅引入自适应边权重学习机制(仍使用简单拼接,无类别嵌入)。GDNN-S 在 GDNN-L 基础上增加类别嵌入。GDNN-T 在 GDNN-W 上增加多头注意力(仍无类别嵌入)。GDNN 为完整模型,在 GDNN-T 基础上引入类别嵌入,整合自适应权重、多头注意力与类别语义。实验对比结果见表 2。

兴趣演变以及融合多源时空信息等方面的局限。模型构建访问序列图与兴趣点地理图的双图协同框架,分别利用 GGNN 和 GCN 捕捉用户兴趣演变及时空特征。创新性地提出了自适应边权重学习机制,通过端到端学习非线性衰减函数替代传统预设的指数衰减形式,该机制采用全局共享参数,使模型能够自动适应不同的地理分布和用户行为模式。引入多头注意力机制融合序列和地理特征,增强了模型的表达能力和可解释性。实验结果表明, GDNN 在 Foursquare 和 Gowalla 数据集上的 NDCG 和 Recall 指标均优于多种基线模型,消融实验进一步证明了各组件的有效性,其中自适应权重学习的贡献最为显著。未来工作可以探索将自适应权重学习机制扩展到更多类型的图(如社交图、语义图),结合多模态数据(如用户评论、POI 图片)进一步增强表示学习,研究模型在冷启动场景下的适应性优化策略。

参考文献:

- [1] Raza S, Rahman M, Kamawal S, et al. A comprehensive review of recommender systems: transitioning from theory to practice [EB/OL]. arXiv:2407.13699, (2024-07-18)

- [2024-11-21]. <https://arxiv.org/abs/2407.13699>.
- [2] Wang Peipei, Lin Li, Wang Ru, et al. Socially-driven multi-interaction attentive group representation learning for group recommendation[J]. Pattern Recognition Letters, 2021, 145: 74-80.
- [3] Wang En, Xu Yong, Yang Ying, et al. Zone-enhanced spatio-temporal representation learning for urban POI recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(9): 9628-9641.
- [4] Wang Xiang, Liu Yong, Zhou Xiangnan, et al. A point-of-interest recommendation method exploiting sequential, category and geographical influence[J]. ISPRS International Journal of Geo-Information, 2022, 11(2): 80.
- [5] 李曼文, 张月琴, 张晨威, 等. 异质图嵌入的地理不敏感时空兴趣点推荐方法[J]. 计算机科学与探索, 2024(3): 755-767.
- [6] 刘浩翰, 任洪润, 贺怀清. 一种基于自注意力机制的组推荐方法[J]. 计算机应用研究, 2020, 37(12): 1-6.
- [7] Lim N, Hooi B, Ng S K, et al. Hierarchical multi-task graph recurrent network for next POI recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid, Spain: ACM, 2022: 1133-1143.
- [8] Jiang Shiyu, He Wei, Cui Liang, et al. Modeling long-and short-term user preferences via self-supervised learning for next POI recommendation[J]. ACM Transactions on Knowledge Discovery from Data, 2023, 17(9): 1-20.
- [9] Acharya M, Mohbey K K, Rajput D S. Long-term preference mining with temporal and spatial fusion for point-of-interest recommendation[J]. IEEE Access, 2024, 12: 11584-11596.
- [10] Hajisafi A, Lin Haowen, Shaham S, et al. Learning dynamic graphs from all contextual information for accurate point-of-interest visit forecasting[C]//Proceedings of the 31st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. Hamburg, Germany: Association for Computing Machinery, 2023: 22:1-22:12.
- [11] Yin Fan, Liu Yu, Shen Zhiqiang, et al. Next POI recommendation with dynamic graph and explicit dependency[C]//Proceedings of the AAAI Conference on Artificial Intelligence. USA: AAAI Press, 2023, 37(4): 4827-4834.
- [12] Wang Tianci, Lai Yantong, Chen Gaode, et al. A dynamic-aware heterogeneous graph neural network for next POI recommendation[C]//PRICAI 2023: Trends in Artificial Intelligence. Singapore: Springer, 2023: 313-326. DOI: 10.1007/978-981-99-7019-3_30.
- [13] Gao Qiang, Wang Wei, Huang Likun, et al. Dual-grained human mobility learning for location-aware trip recommendation with spatial-temporal graph knowledge fusion[J]. Information Fusion, 2023, 92: 46-63.
- [14] Wang Zhen, Zhu Yu, Wang Chao, et al. Adaptive graph representation learning for next POI recommendation[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. Taipei, Taiwan, China: ACM, 2023: 393-402.
- [15] Qin Yifan, Wang Yanhua, Sun Fei, et al. DisenPOI: disentangling sequential and geographical influence for point-of-interest recommendation[C]//Proceedings of the 16th ACM International Conference on Web Search and Data Mining. Singapore, Singapore: ACM, 2023: 508-516.
- [16] Yang Shuang, Liu Jie, Zhao Kai. GETNext: trajectory flow map enhanced transformer for next POI recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid, Spain: ACM, 2022: 1144-1153.
- [17] Luo Yong, Liu Qiang, Liu Zhiwei, et al. STAN: spatio-temporal attention network for next location recommendation[C]//Proceedings of the Web Conference 2021. Ljubljana, Slovenia: ACM, 2021: 2177-2185.
- [18] Qin Yifan, Wu Hongzhi, Ju Wenjun, et al. A diffusion model for POI recommendation[J]. ACM Transactions on Information Systems, 2023, 42(2): 1-27.
- [19] Wu Zonghan, Pan Shirui, Chen Fengwen, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 4-24.
- [20] Gilmer J, Schoenholz S S, Riley P F, et al. Neural message passing for quantum chemistry[C]//Proceedings of the 34th

- International Conference on Machine Learning. Sydney, Australia, 2017: 1263-1272.
- [21] Xu Zhe, Wei Pengfei, Liu Shichao, et al. Correlative preference transfer with hierarchical hypergraph network for multi-domain recommendation[C]//Proceedings of the ACM WebConference 2023. Austin, TX, USA: Association for Computing Machinery, 2023: 983-991.
- [22] Gan Ming, Ma Yu. Mapping user interest into hyper-spherical space: a novel POI recommendation method[J]. Information Processing & Management, 2023, 60(2): 103169.
- [23] Liu Yong, Miao Huaxiu, Shen Guangming, et al. SPOT-Trip: dual-preference driven out-of-town trip recommendation [EB/OL]. arXiv:2506.01705, (2025-06-03) [2025-11-21]. <https://arxiv.org/abs/2506.01705>.
- [24] Song Chao, Ren Zhaochun, Lu Lei. Integrating personalized spatio-temporal clustering for next POI recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2025, 39(12): 12550-12558.
- [25] Thaisutikul T, Chen Yingnong. An improved deep sequential model for context-aware POI recommendation[J]. Multimedia Tools and Applications, 2024, 83(1): 1643-1668.
- [26] Zhang Jianxin, Liu Xiaoli, Zhou Xiaofeng, et al. Leveraging graph neural networks for point-of-interest recommendations[J]. Neurocomputing, 2021, 462: 1-13.
- [27] Chang Buru, Jang G, Kim S, et al. Learning graph-based geographical latent representation for point-of-interest recommendation[C]//Proceedings of the 29th ACM International Conference on Information and Knowledge Management. Galway, Ireland: ACM, 2020: 135-144.
- [28] He Xiangnan, Deng Kuan, Wang Xiang, et al. LightGCN: simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Xi'an, China: ACM, 2020: 639-648.