

陈俊, 欧阳锦滔, 张祯. 基于自监督超图注意力网络的兴趣点推荐[J]. 智能计算机与应用, 2026, 16(3): 109-114. DOI: 10.20169/j. issn. 2095-2163. 24051602

基于自监督超图注意力网络的兴趣点推荐

陈俊^{1,2}, 欧阳锦滔^{1,2}, 张祯³

(1 沈阳化工大学 计算机科学与技术学院, 沈阳 110142; 2 辽宁省化工过程工业智能化技术重点实验室, 沈阳 110142;
3 营口理工学院 电气工程学院, 辽宁 营口 115014)

摘要: 兴趣点推荐旨在分析用户的签到信息并预测用户下一个最有可能访问的地点。近年来, 循环神经网络被广泛应用于推荐系统, 取得了一定成效。然而这些方法难以学习到复杂的高阶信息。为了克服这些局限性, 本文提出了一种基于自监督的超图注意力网络模型用于兴趣点推荐。该模型首先将用户的签到轨迹建模为超图, 然后基于注意力机制设计一种特定于节点和超边的超图注意力网络, 通过节点-超边-节点两步信息聚合学习节点的高质量嵌入, 最后将节点信息聚合得到用户偏好表示。此外, 为了缓解推荐系统中数据稀疏的问题, 使用门控循环单元从原始数据中挖掘序列监督信号, 通过自监督学习来增强用户表示, 提高推荐性能。在3个社交网络公开数据集上的实验证明, 该模型优于其它兴趣点推荐的基线模型。

关键词: 兴趣点推荐; 自监督学习; 超图网络; 注意力机制

中图分类号: TP391.1 **文献标志码:** A **文章编号:** 2095-2163(2026)03-0109-06

Point Of Interest recommendation based on self-supervised hypergraph attention network

CHEN Jun^{1,2}, OUYANG Jintao^{1,2}, ZHANG Zhen³

(1 College of Computer Science and Technology, Shenyang University of Chemical Technology, Shenyang 110142, China;
2 Liaoning Key Laboratory of Intelligent Technology for Chemical Process Industry, Shenyang 110142, China;
3 College of Electrical Engineering, Yingkou Institute of Technology, Yingkou 115014, Liaoning, China)

Abstract: Point-Of-Interest (POI) recommendation aims to analyze the user's check-in data and predict the next most probable location for the user to visit. Recurrent neural networks have been widely utilized in recommendation systems with some success, but they struggle to capture complex high-order information. To address these limitations, this paper proposes a self-supervised hypergraph attention network model for POI recommendation. Firstly, the user's check-in trajectory is represented as a hypergraph, and then a node and hyperedge-specific hypergraph attention network is designed based on the attention mechanism, enabling high-quality embedding of nodes through node-hyperedge-node two-step information aggregation. Finally, the node information is aggregated to derive the user preference representation. Additionally, in order to mitigate data sparsity issues in recommendation systems, gated recurrent unit is employed to extract sequence supervision signals from raw data and enhance user representation through self-supervised learning for improved recommendation performance. Experiments on three public social network datasets demonstrate that the proposed model outperforms other baseline models for POI recommendation.

Key words: POI recommendation; self-supervised learning; hypergraph network; attention mechanism

0 引言

随着互联网技术的发展和移动设备的普及, Foursquare、Yelp 和大众点评等基于位置的社交网络

(Location-based Social Networks, LBSNs) 服务吸引了大量用户, 这些服务允许用户登记和分享自己的位置和生活经历。大量的历史登记数据为服务提供商提供了宝贵的信息, 为了提高用户体验, 兴趣点

基金项目: 辽宁省教育厅青年基金(LJKQZ2021184); 辽宁省自然科学基金(2022-YKLH-18, 2023-MSLH-311); 营口理工学院重点研究项目基金(ZDIL202305)。

作者简介: 陈俊(1999—), 男, 硕士研究生, 主要研究方向: 兴趣点推荐; 欧阳锦滔(1998—), 男, 硕士研究生, 主要研究方向: 数据挖掘。

通信作者: 张祯(1991—), 女, 博士, 副教授, 主要研究方向: 基于位置社交网络分析与挖掘。Email: zhangzhen@yku.edu.cn。

收稿日期: 2024-05-16

(Point Of Interest, POI) 推荐引起了广泛关注^[1-4]。

POI 推荐的目的是分析用户的签到数据来预测用户下一个最有可能访问的地点。早期的方法主要集中在马尔科夫链^[5-6]和矩阵分解^[7]上。随着计算资源和海量训练数据的增加,深度学习方法在推荐系统中取得了显著进展。研究人员提出大量的基于循环神经网络(Recurrent Neural Network, RNN)^[8]以及相关变体,如长短期记忆(Long Short-Term Memory, LSTM)^[9]网络和门控循环单元(Gated Recurrent Unit, GRU)^[10]网络的模型用于 POI 推荐。ST-RNN^[11]利用 2 次连续访问之间的时空间隔作为辅助信息融入到 RNN 的间隔中,提高了模型性能。Time-LSTM^[12]专门设计了一种时间门加入到 LSTM 结构中更好地学习了时空信息。STGN^[13]在 LSTM 的基础上增加了一个时空门,提出了一种记忆增强方法用来捕获用户的长短期偏好。LSTPM^[14]提出了一种地理扩张的 LSTM 结构,聚合了用户最近访问的位置信息,对用户短期偏好建模。

然而这些模型忽略了非相邻 POI 和非连续签到的相关性。由于注意力机制可以捕捉序列数据中不同成分的重要程度,有助于获得更准确的用户偏好。注意力机制与各种神经网络架构相结合,已被证明在推荐任务中是有效的^[15]。ATST-LSTM^[16]是一种包含时空信息的注意力机制网络,但未考虑类别转换偏好信息。Zheng 等学者^[17]研究了层次注意力网络对 POI 推荐记忆增强的影响。Liu 等学者^[18]开发了一种基于注意力机制的类别感知 GRU 模型,该模型利用注意力机制关注用户签到序列中的历史签到信息,将 POI 类别作为用户偏好来训练模型。Xia 等学者^[19]设计了一种应用在轨迹内和轨迹间的注意力机制,充分利用历史签到中的周期模型,更好地模拟用户的移动规律。文献[20]提出了一种具有 2 种机制的历史注意力模型,用一种原则性的方式捕捉多层次的用户周期性,通过嵌入影响人类移动的多种因素来捕捉复杂的序列转换。

然而,这些模型都将 POI 推荐视为序列任务,过于强调两两之间的成对关系,难以捕获到用户轨迹内超越成对关系的高阶信息,阻碍了用户偏好建模,影响推荐性能。超图^[21]提供了一种表达和捕获高阶关系的自然方法,但其在 POI 推荐的潜力尚未得到开发。因此,本文提出了一种基于自监督的超图注意力网络(Self-Supervised Hypergraph Attention Network, SS-HAN)模型用于 POI 推荐。该模型首先用超图结构来建模用户的签到轨迹,其次将注意力

机制引入到超图神经网络,设计了一种用于节点和超边的注意力机制网络用来捕获高阶关系,此外为了缓解推荐系统中普遍存在的数据稀疏性问题,本文结合了先前方法的优势,将自监督学习^[22]集成到网络模型中,从原始数据挖掘顺序依赖关系作为监督信息对用户进行数据增强。具体来说,分别使用超图注意网络和 GRU 学习 2 种用户偏好信息,以同时考虑高阶关系和顺序依赖关系,为缓解数据稀疏性问题,设计了一种自监督学习范式将 2 种用户表示之间的信息最大化,提高推荐效果。

1 SS-HAN 模型

1.1 符号说明

设用户集合为 $U = \{u_1, u_2, \dots, u_N\}$, 这里 N 表示用户数, POI 集合为 $P = \{p_1, p_2, \dots, p_M\}$, 这里 M 是 POI 的数量。用户的每次访问会产生一条记录 p_i , 将用户的所有签到记录按照时间顺序排列在一起形成用户的签到轨迹。例如,给定一个用户 $u \in U$, 其签到轨迹为 $q_u = \{p_1, p_2, \dots, p_n\}$ 。所有用户的签到轨迹设为 $Q = \{q_1, q_2, \dots, q_N\}$ 。POI 推荐的目标就是给定所有用户的签到轨迹 Q , 通过推荐模型预测,输出所有 POI 的推荐得分 $y = [y_1, y_2, \dots, y_M]$, 并选取 y 中分数最高的前 k 项推荐给用户。

1.2 模型概述

图 1 展示了本文所提出的基于自监督超图注意力网络(SS-HAN)模型的整体框架。由图 1 可知, SS-HAN 分为 3 个模块:超图表示学习模块、序列表示学习模块和自监督学习模块。

(1)超图表示学习模块。首先将用户的签到轨迹构建为超图,然后引入注意力机制,分别计算所有节点和超边的权重进行信息传播和聚合,在得到高质量嵌入的节点特征后,使用软注意力机制进行聚合形成用户表示。

(2)序列表示学习模块。将用户签到数据进行序列建模,通过 GRU 捕获用户的顺序依赖表示。

(3)自监督学习模块。将上述 2 个模块学习到的用户表示进行自监督学习,有助于学习到更多的语义信息和上下文信息,进一步实现了数据增强。通过使用自监督学习作为辅助任务,有效缓解了 POI 推荐中数据稀疏的问题,提高了模型性能。

1.2.1 超图表示学习模块

本文使用超图来建模用户的签到轨迹,每条超边表示一个用户,每个节点表示用户的签到 POI。传统的 HGNN 在聚合信息时平等地对待所有节点和超边

的重要性,这种机制并不适应用户复杂多变的动态偏好。因此,本文设计了一种特定于节点和超边的超图注意力机制网络(Hypergraph Attention Network,

HAN),计算超图中不同节点和超边的不同权重,然后通过权重自适应地聚合节点和超边信息,图 2 展示了 HAN 的基本结构,该网络分为 2 个阶段。

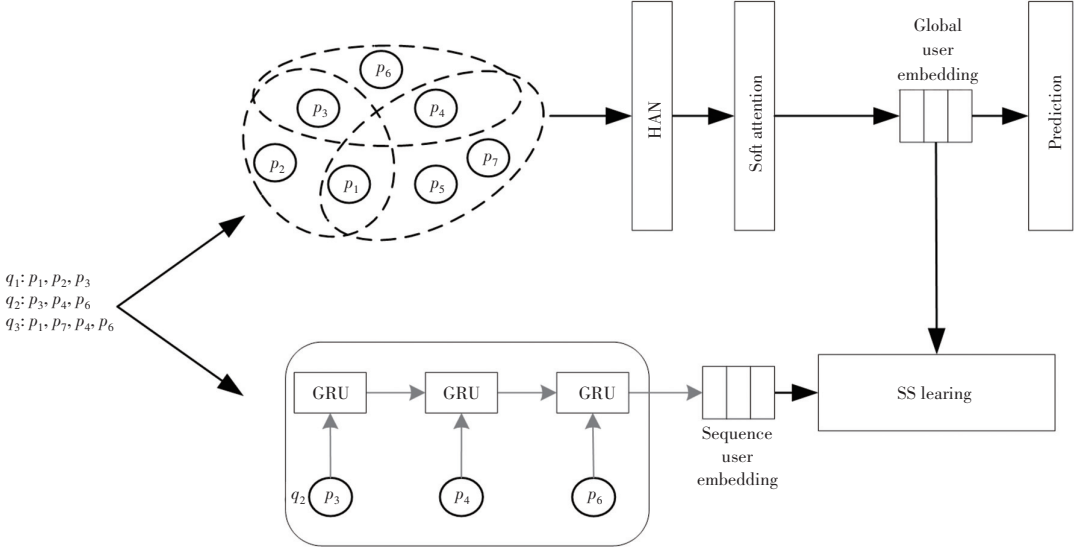


图 1 本文模型的框架结构图

Fig. 1 The framework structure diagram of the model in this paper




图 2 超图注意力网络

Fig. 2 Hypergraph Attention Network

(1) 节点-超边注意力机制: 给定一条超边 q_j , 首先计算超边中所有节点的权重, 然后使用权重聚合节点特征形成超边特征, 计算公式如下:

$$\alpha_{p_i}^{q_j} = \frac{\exp(\text{LeakyRelu}(\mathbf{a}_{q_j}^T \cdot \mathbf{v}_{p_i}^{(l)}))}{\sum_{p_k \in S_{q_j}} \exp(\text{LeakyRelu}(\mathbf{a}_{q_j}^T \cdot \mathbf{v}_{p_k}^{(l)}))} \quad (1)$$

$$\mathbf{e}_{q_j}^{(l)} = \sum_{p_k \in q_j} \alpha_{p_k}^{q_j} \cdot \mathbf{v}_{p_k}^{(l)} \quad (2)$$

其中, $\alpha_{p_i}^{q_j}$ 表示节点 p_i 对超边 q_j 的重要程度; $\mathbf{a}_{q_j}^T \in \mathbb{R}^d$ 表示超边 q_j 的可学习注意参数; $\text{LeakyRelu}(\cdot)$ 表示一个激活函数; S_{q_j} 表示超边 q_j 的节点聚合; $\mathbf{v}_{p_k}^{(l)} \in \mathbb{R}^d$ 表示第 l 层的节点特征; $\mathbf{e}_{q_j}^{(l)}$ 表示第 l 层的超边特征。

(2) 超边-节点注意力机制: 给定一个节点 p_i , 计算包含该节点的所有超边的注意力权重, 然后聚合超边特征得到节点特征, 计算公式如下:

$$\beta_{q_j}^{p_i} = \frac{\exp(\text{LeakyRelu}(\mathbf{b}_{p_i}^T \cdot \mathbf{e}_{q_j}^{(l)}))}{\sum_{q_k \in S_{p_i}} \exp(\text{LeakyRelu}(\mathbf{b}_{p_i}^T \cdot \mathbf{e}_{q_k}^{(l)}))} \quad (3)$$

$$\mathbf{v}_{p_i}^{(l)} = \sum_{q_k \in S_{p_i}} \beta_{q_k}^{p_i} \cdot \mathbf{e}_{q_k}^{(l)} \quad (4)$$

其中, $\beta_{q_j}^{p_i}$ 表示超边 q_j 对节点 p_j 的重要程度; $\mathbf{b}_{p_i}^T \in \mathbb{R}^d$ 表示节点 p_i 的可学习注意参数; S_{p_i} 表示包含节点 p_i 的超边集合。经过多层学习之后得到用户签到轨迹中的所有 POI 的全局高阶嵌入 $\mathbf{e}^u = \{e_{p_1}, e_{p_2}, \dots, e_{p_n}\}$ 。根据文献[23]的建议, 本文引入一个可学习的位置矩阵 $\mathbf{S} = \{s_1, s_2, \dots, s_n\}$ 来考虑用户签到轨迹的位置信息, 将反向位置嵌入和全局嵌入进行连接, 用户签到轨迹中第 i 个 POI 表示为:

$$\mathbf{x}_i = \tanh(\mathbf{W}_1 [e_{p_i} \parallel s_{n-i+1}] + \mathbf{b}) \quad (5)$$

其中, $\mathbf{W}_1 \in \mathbb{R}^{d \times 2d}$ 和 $\mathbf{b} \in \mathbb{R}^d$ 是可学习参数。然后使用软注意力机制聚合得到用户偏好表示:

$$\mathbf{u} = \sum_{i=1}^n \gamma_i \cdot \mathbf{x}_i \quad (6)$$

其中, 每个项目的权重 $\gamma_i = \mathbf{f}^T \sigma(\mathbf{W}_2 \cdot \mathbf{x}_i + \mathbf{c})$, $\mathbf{f}^T \in \mathbb{R}^d$, $\mathbf{W}_2 \in \mathbb{R}^{d \times d}$ 和 $\mathbf{c} \in \mathbb{R}^d$ 都是可学习的参数。

1.2.2 序列表示学习模块

由于用户的签到轨迹具有较强的时间顺序相关性^[12], 本文使用门控循环单元网络来捕获用户签到轨迹的长期依赖关系, 给定一个用户 u 的初始化序列特征 $\{f_1, f_2, \dots, f_n\}$, 学习过程如下:

$$\begin{cases} h_1 = \text{GRU}(f_1, h_0) \\ h_2 = \text{GRU}(f_2, h_1) \\ \dots \\ h_n = \text{GRU}(f_n, h_{n-1}) \end{cases} \quad (7)$$

其中, $\text{GRU}(\cdot, \cdot)$ 为 GRU 的一次处理; h_i 为上一时刻的隐藏状态输出, 本文使用最后一次的输入作为用户的序列偏好 $h = h_n$ 。

1.2.3 自监督学习模块

超图表示学习使本文所提模型获得了出色性能。然而, 签到数据的稀疏性和序列信息的缺失可能会影响超图建模。为此本文将自监督学习集成到模型训练中, 将用户的 2 种表示之间的互信息最大化, 从而使模型可以学到更多的信息。本文遵循文献[24]的建议将二元交叉熵损失作为本文的学习目标, 定义为:

$$L_s = -\log \sigma(f_D(\theta_i^a, \theta_i^b)) - \log \sigma(1 - f_D(\tilde{\theta}_i^a, \theta_i^b)) \quad (8)$$

其中, f_D 表示一个鉴别函数, 用于区分不同输入的特征。本文将简单地设计为 2 个向量的点积, 度量 2 个向量之间的相似性或一致性; $\tilde{\theta}_i^a$ 是 θ_i^a 逐行逐列变换得到的负样本。

1.2.4 预测和优化

将超图表示学习模块得到的用户表示和 POI 嵌入进行内积运算, 然后使用 Softmax 函数归一化计算下一个 POI 的预测概率。用到的公式为:

$$\hat{y}_i = \text{Softmax}(u^T x_i) \quad (9)$$

在模型训练中使用交叉熵损失函数对目标进行优化, 公式为:

$$L_r = -\sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (10)$$

其中, y 表示 one-hot 向量表示的真实值。

最后, 将推荐任务损失和自监督学习损失结合得到模型总损失, 定义公式为:

$$L = \mu L_r + (1 - \mu) L_s \quad (11)$$

其中, μ 表示调整 2 个损失函数的权重。

2 实验结果与分析

2.1 数据集

为了证明 SS-HAN 模型的有效性, 本文在 LBSNs 中被广泛使用的 3 种公开数据集上进行评估实验。其中, Foursquare 数据集是 2010 年 2 月到 2011 年 1 月在纽约收集的签到数据; Gowalla 数据集是 2009 年 2 月到 2010 年 10 年在全球范围内的签到数据; Yelp 数据集是 Yelp 挑战赛 (2016 年 2

月) 期间在北美和欧洲签到的数据集。数据集的基本信息见表 1。

表 1 数据集基本信息

Table 1 Basic information of the datasets			
数据集	用户数	兴趣点数	签到数
Foursquare	934	9 296	52 983
Gowalla	5 802	40 868	301 080
Yelp	7 135	16 621	301 753

本文遵循文献[14]的做法, 过滤掉 Gowalla 数据集中签到数少于 20 的用户以及访问数少于 20 的 POIs, 同样对于 Foursquare 和 Yelp 数据集过滤掉签到数少于 10 的用户以及访问数少于 10 的 POIs。此外, 将训练集、测试集和验证集按照 7 : 2 : 1 的比例进行划分。

2.2 评估指标

为了对所提模型的性能进行有效评估, 本文选用了推荐系统中广泛使用的 2 个评价指标: 召回率 (Recall@K) 和归一化折损累计增益 (NDCG@K)。Recall@K 判断在推荐的前 K 的 POI 中是否存在正确的 POI, NDCG@K 衡量在推荐的前 K 的 POI 中正确的 POI 的排名。

2.3 参数设置和对比方法

本文将特征嵌入维度和批处理大小设置为 100, 超参数 μ 设置为 0.000 5, 超图注意力网络层数设置为 3。所有的权重参数都遵循文献[25]进行 Xavier 初始化。学习率初始为 0.000 1, 使用 Adam 进行优化, 训练迭代次数设为 30。为了保证实验的公平性, 所有的实验都训练 10 次, 并取平均值作为最终结果。

已有的研究表明^[13]: 基于深度学习的方法相较于传统方法如马尔科夫链、矩阵分解具有更好的性能和效果。因此, 本文与基于深度学习的 POI 推荐模型进行对比, 来证明本文所提模型的有效性。

(1) ST-RNN^[11]: 基于 RNN 的模型, 在循环结构中结合时空信息进行 POI 推荐。

(2) LSTPM^[14]: 将用户的签到轨迹分为历史轨迹和当前轨迹, 使用 LSTM 分别捕获用户的长期偏好和短期偏好。

(3) STGN^[13]: 对 LSTM 进行改进, 是一种增强长短期记忆的时空门控网络, 使用 2 个时间门和距离门来捕获连续签到之间的时空关系。

(4) DeepMove^[20]: 首先使用 GRU 来学习用户签到轨迹的顺序关系和长期偏好, 然后使用注意力机制将历史记录嵌入到独立的潜在向量, 预测用户

移动的周期性。

(5) STAN^[26]: 是一种双层注意力架构, 首先聚合用户轨迹内的时空相关性更新用户表示, 然后将目标与所有签入进行匹配。

2.4 实验结果

本文在 K 设置为 5 的情况下评估不同模型的性能, 结果见表 2。从实验结果中可以看出, 本文所提模型在 3 个数据集上的 2 种评估指标都优于其它模型。LSTPM^[14] 使用 LSTM 来捕获用户的长短期偏好, 在性能上优于使用传统 RNN 的 ST-RNN^[11] 模型。STGN^[13] 改进了 LSTM 的结构, 添加了一个时间

门和距离门来建模时空关系, 性能上优于其它 2 个模型。DeepMove^[20] 是一种结合注意力机制和循环神经网络的方法, 通过不同的角度学习用户表示, 而 STAN^[26] 是一种纯注意力机制的模型, 使用 2 个注意力层进行信息聚合和学习。由于注意力机制可以动态地学习用户偏好, 整体效果上优于使用 RNN 的模型。然而这些方法都采用序列建模, 没有考虑高阶相关性, 影响用户偏好建模。本文提出的 SS-HAN 模型将注意力机制引入到超图表示学习中, 充分捕获用户的非线性相关性。此外, 本文还使用自监督学习对超图建模进行数据增强。

表 2 不同模型在数据集上的实验结果

Table 2 Experimental results of different models on datasets

Model	Foursquare		Gowalla		Yelp	
	Recall@5	NDCG@5	Recall@5	NDCG@5	Recall@5	NDCG@5
ST-RNN ^[11]	0.167 9	0.076 8	0.142 2	0.083 5	0.215 6	0.071 3
LSTPM ^[14]	0.201 5	0.153 6	0.183 5	0.112 5	0.283 2	0.113 4
STGN ^[13]	0.273 0	0.142 5	0.172 6	0.156 3	0.342 9	0.165 4
DeepMove ^[20]	0.351 6	0.181 3	0.203 4	0.183 6	0.324 5	0.203 5
STAN ^[26]	0.321 8	0.215 4	0.234 5	0.235 8	0.384 3	0.265 4
SS-HAN	0.415 6	0.265 2	0.315 6	0.293 4	0.428 6	0.318 6

3 结束语

面对用户复杂多变的兴趣, 现有的 POI 推荐方法难以满足用户的偏好需求, 本文提出了一种基于自监督学习的超图注意力网络推荐模型。该模型将注意力机制应用到超图学习中, 更好地利用超图结构学习用户与 POI 的高阶关系, 而非成对关系。其次, 本文结合了先前研究的优势, 使用 GRU 来捕获用户的长期偏好和顺序关系。最后, 使用自监督学习产生的自监督信号对超图学习进行信息补充, 有效缓解了推荐中的数据稀疏问题。在公开的数据集上进行对比实验, 证明了本文模型的有效性。今后的研究中, 考虑将用户签到的上下文信息融合到超图表示学习中, 更好地对用户偏好进行建模。

参考文献

- [1] 刘国岐, 何延年, 荣艺焯, 等. 基于用户轨迹和好友关系的兴趣点推荐[J]. 计算机工程与科学, 2024, 46(9): 1693-1701.
- [2] 李勇, 韩志媛, 安敬民. 基于循环神经网络的实时偏好感知兴趣点推荐[J]. 计算机工程与设计, 2023, 44(12): 3772-3777.
- [3] FENG S, CONG G, AN B, et al. Poi2vec: Geographical latent representation for predicting future visitors[J]. Proceedings of the AAAI Conference on Artificial Intelligence. 2017, 31(1): 102-108.
- [4] ZHAO S, KING I, LYU M R. A survey of point-of-interest

recommendation in location-based social networks [J]. arXiv preprint arXiv, 1607. 00647, 2016.

- [5] RENDLE S. Factorization machines with libfm [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2012, 3(3): 57.
- [6] ZHAO S, ZHAO T, YANG H, et al. STELLAR: Spatial-temporal latent ranking for successive point-of-interest recommendation [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2016, 30(1): 315-322.
- [7] LIAN Defu, ZHAO Cong, XIE Xing, et al. GeoMF: Joint geographical modeling and matrix factorization for point-of-interest recommendation [C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 831-840.
- [8] QUADRANA M, KARATZOGLOU A, HIDASI B, et al. Personalizing session-based recommendations with hierarchical recurrent neural networks [C]//Proceedings of the Eleventh ACM Conference on Recommender Systems. New York: ACM, 2017: 130-137.
- [9] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [10] ZHANG Zhiqian, LI Chenliang, WU Zhiyong, et al. Next: a neural network framework for next poi recommendation [J]. Frontiers of Computer Science, 2020, 14: 314-333.
- [11] LIU Q, WU S, WANG L, et al. Predicting the next location: A recurrent model with spatial and temporal contexts [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2016, 30(1): 194-200.
- [12] ZHU Y, LI H, LIAO Y, et al. What to do next: Modeling user behaviors by time-LSTM [C]//Proceedings of the 26th

- International Joint Conference on Artificial Intelligence. Melbourne, Australia; AAAI, 2017; 3602–3608.
- [13] ZHAO Pengpeng, LUO Anjing, LIU Yanchi, et al. Where to go next: A spatio-temporal gated network for next poi recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(5): 2512–2524.
- [14] SUN K, QIAN T, CHEN T, et al. Where to go next: Modeling long- and short-term user preferences for point-of-interest recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 214–221.
- [15] ZHANG Y, DAI H, XU C, et al. Sequential click prediction for sponsored search with recurrent neural networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2014, 28(1): 1369–1375.
- [16] HUANG Liwei, MA Yutao, WANG Shibo, et al. An attention-based spatiotemporal lstm network for next poi recommendation [J]. IEEE Transactions on Services Computing, 2019, 14(6): 1585–1597.
- [17] ZHENG Chenwang, TAO Dan, WANG Jiangtao, et al. Memory augmented hierarchical attention network for next point-of-interest recommendation[J]. IEEE Transactions on Computational Social Systems, 2020, 8(2): 489–499.
- [18] LIU Yuwen, PEI Aixiang, WANG Fan, et al. An attention-based category-aware GRU model for the next POI recommendation[J]. International Journal of Intelligent Systems, 2021, 36(7): 3174–3189.
- [19] XIA T, QI Y, FENG J, et al. Attnmove: History enhanced trajectory recovery via attentional network[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4494–4502.
- [20] FENG Jie, LI Yong, ZHANG Chao, et al. Deepmove: Predicting human mobility with attentional recurrent networks [C]// Proceedings of the 2018 World Wide Web Conference. Lyons, France; IW3C2, 2018; 1459–1468.
- [21] FENG Y, YOU H, ZHANG Z, et al. Hypergraph neural networks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 3558–3565.
- [22] LIU Xiao, ZHANG Fanjin, HOU Zhenyu, et al. Self-supervised learning: Generative or contrastive [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(1): 857–876.
- [23] XIA X, YIN H, YU J, et al. Self-supervised hypergraph convolutional networks for session-based recommendation [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5): 4503–4511.
- [24] OORD A, LI Y, VINYALS O. Representation learning with contrastive predictive coding [J]. arXiv preprint arXiv, 1807.03748, 2018.
- [25] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C]// Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. Sardinia, Italy; PMLR, 2010: 249–256.
- [26] LUO Y, LIU Q, LIU Z. STAN: Spatio-temporal attention network for next Point-of-Interest recommendation [C]// Proceedings of ACM Web Conference (WebConf). New York: ACM, 2021; 2177–2185.