

文章编号: 2095-2163(2023)12-0120-05

中图分类号: TP183

文献标志码: A

融合时空信息个性化旅游兴趣点推荐算法

潘 兰, 魏嘉银, 卢友军, 干 霞

(贵州民族大学 数据科学与信息工程学院, 贵阳 550025)

摘要: 针对个性化旅游兴趣点推荐算法中存在的问题,如忽视序列图中节点间的时空信息及未能充分利用空间相关性,本文提出了一种融合时空信息个性化旅游兴趣点推荐算法。运用自注意力机制获取用户的动态信息,将其作为图神经网络中用户和兴趣点的时空特征,并参与领域信息的聚合。实验表明,该算法具有可行性,能够有效提升推荐性能。

关键词: 自注意力机制; 图神经网络; 个性化旅游兴趣点推荐

Recommend personalized tourist attractions based on spatial-temporal information

PAN Lan, WEI Jiayin, LU Youjun, GAN Xia

(School of Data Science and Information Engineering, Guizhou Minzu University, Guiyang 550025, China)

Abstract: Aiming to address the issues in personalized tourism point-of-interest recommendation algorithms, specifically the neglect of spatio-temporal information between nodes in sequence graphs and the inadequate utilization of spatial correlation, this paper introduces a recommended personalized tourist attractions based on spatial-temporal information algorithm that is founded on the self-attention mechanism. This algorithm employs the attention mechanism to capture the dynamic information of users, treating these as the spatio-temporal features of both users and points of interest within the graph neural network, and engages in the aggregation of domain-specific information. Experimental results demonstrate the viability of this method and its ability to significantly enhance recommendation performance.

Key words: self-attention mechanism; graph neural network; personalized tourism interest point recommendation.

0 引言

基于位置服务的普及,用户在社交平台上分享旅游兴趣点(Point-of-Interest, POI)的签到和评论已成为一种流行趋势^[1]。丰富的用户签到数据推动了兴趣点推荐系统的发展,该系统可模拟用户访问偏好并预测最可信的下一个POI,历史签到数据为服务商提供了宝贵信息,揭示了用户的行为模式,该系统可帮助用户决定下一个目的地和计划行程。

序列效应在旅游兴趣点推荐中至关重要,现有研究主要针对序列转换,已逐渐被基于神经网络的方法取代。Wang等^[2]提出了全局时空感知图神经网络模型,捕捉全局时空关系;Liu等^[3]考虑POI动态时效性,提出了一种交互增强且时间感知的图卷积网络模型,用于连续的POI推荐;Capanema等^[4]

结合循环神经网络(RNN)和图神经网络(GNN)预测下一个POI类别;Wang等^[5]使用图神经网络(GNN)和用户与POI之间的复杂相关性进行推荐;Zhang等^[6]提出深度卷积和多头自注意力位置网络模型,模型用于位置的智能推荐;Tsai等^[7]利用用户生成内容推荐游览序列。虽然基于时空信息的兴趣点已被广泛研究,但仍存在空间相关性利用不足的问题。Cao等^[8]提出轨迹感知动态图卷积网络,捕获局部空间相关性;Lai等^[9]提出多视图时空增强超图网络进行下一个POI推荐;Ou J等^[10]使用增强时序卷积网络学习顺序转换相关性,进行下一个POI推荐;Li Q等^[11]提出基于注意力的时空门控图神经网络模型进行序列推荐;Li H等^[12]提出时空意向学习自我意向网络,捕捉用户长期偏好,识别特定时间重访特定POI的意向。

基金项目: 贵州省教育厅自然科学研究项目(黔教技[2022]015号);贵州省省级科技计划项目资助(黔科合基础[2018]1082,黔科合基础[2019]1159号);贵州省科技计划项目(QKHJCZK2022YB195, QKHJCZK2023YB143, QKHPTRCZCKJ2021007)。

作者简介: 潘 兰(1997-),女,硕士研究生,主要研究方向:海量数据统计与分析、推荐算法;卢友军(1987-),男,博士,副教授,主要研究方向:复杂系统与大数据分析;干 霞(1997-),女,硕士研究生,主要研究方向:海量数据统计与分析。

通讯作者: 魏嘉银(1986-),男,博士,副教授,主要研究方向:大数据分析与管理、推荐算法设计与分析。Email:weijiayin05@sina.com

收稿日期: 2023-10-18

哈尔滨工业大学主办 ◆ 专题设计与应用

1 个性化旅游兴趣点推荐算法模型

1.1 时空特征捕获层

为了更好地考虑轨迹中两次访问之间的不同空间距离和时间间隔, 时空特征捕获层旨在聚合相关 POI 并更新访问表示, 通过引入自注意层捕捉长期依赖并为每次访问分配权重。将时空上下文纳入序列建模, 可提升模型对局部 POI 的关注和推荐结果的可解释性。将用户、旅游兴趣点和时间戳集合分别表示为 $U = \{u_1, u_2, \dots, u_U\}$, $P = \{p_1, p_2, \dots, p_P\}$ 和 $T = \{t_1, t_2, \dots, t_T\}$, 序列 $S^u = \{c_1^u, c_2^u, \dots, c_{S^u}^u\}$ 其中 c_j^u 是用户 u 的第 j 次签到记录。通过不同的参数矩阵 $W_Q, W_K, W_V \in \mathbb{R}^{d \times d}$ 进行转换获得新的序列 S^u , 式(1):

$$S^u = \text{attention}(E_u W_Q, E_u W_K, E_u W_V, E(\Delta), M) \quad (1)$$

自注意力机制函数定义, 式(2):

$$h^{T_u} = \text{softmax}(M * (\frac{\theta K^T}{\sqrt{d_0}} + E^A)) V \quad (2)$$

其中, h^{T_u} 表示注意力输出嵌入矩阵; $d_0 = \frac{d}{h}$, h

是注意力头数; $\sqrt{d_0}$ 是尺度因子, 用于避免因点积归一化过大而导致的消失梯度; $\theta, K, V \in \mathbb{R}^{l \times d}$ 表示序列的查询、键和值向量, 在自注意力中 $\theta = K = V$; E^A 表示时空上下文矩阵 A_d 插值嵌入的输出; Wang 等^[13]将矩阵 $M \in \mathbb{R}^{l \times l}$, $\frac{\theta K^T}{\sqrt{d_0}} \in \mathbb{R}^{l \times l}$ 其上三角元素填满 “ $-\infty$ ”, 则元素与元素相乘; softmax 函数用于将这些分数归一化为注意力权重。最终的空间用户输入嵌入 T_p 使用和 T_u 同样的计算方法。

使用多头注意力从不同的潜在视角来捕获时空信息, 并输入到前馈神经网络中, 最终用户和 POI 的时空信息输出, 式(3)和式(4):

$$h_u = FFN(h_1^{T_u} \dots \| h_k^{T_u} \dots \| h_k^{T_u}) \quad (3)$$

$$h_p = FFN(h_1^{T_p} \dots \| h_k^{T_p} \dots \| h_k^{T_p}) \quad (4)$$

其中, k 表示注意力函数的数量。

1.2 区域子图设置模块

为优化推荐算法, 本文设置了一个区域子图设置模块, 以加强相似用户间的影响并减弱不相似用户间的影响。每个用户由特征向量表示, 包括图空间特征和地理空间特征。本文为使用归一化的经纬度数据来确定地理空间特征, 并利用特征向量将兴趣相似的用户分组到同一子图中。在子图构建中,

不相似用户的连接会被弱化或断开, 以降低其负面影响。该模块结合了图空间和地理空间信息。用户特征向量可以表示为式(5):

$$Feature_u = \sigma(W_1(e_u^{(1)} + e_{up}) + b_1) \quad (5)$$

其中, $e_u^{(1)}$ 表示第一层图卷积后的用户嵌入, 即通过聚合一阶相邻 POI 获得的图空间结构; e_{up} 表示用户最频繁访问的 POI 地理位置; $\sigma(\cdot)$ 是激活函数; W_1 和 b_1 分别表示权重矩阵和偏置矢量。

获得用户特征向量后, 使用三层神经网络投影获得用户特征, U 表示用户投影得到分类预测向量, 式(6):

$$U = W_4(W_3 Feature_u + b_3) + b_4 \quad (6)$$

其中, W_3, W_4 和 b_3, b_4 分别表示权重矩阵和偏置矢量。

相似用户归入同一区域子图。确定子图数量后, 用户只收集所在子图内的邻近信息, 降低不相似用户间的影响。

1.3 时空图神经网络模块

根据用户数据构造用户矩阵二分图签到序列二分图 $G = (Q, E)$, $Q = \{q_i^u\}_{i=1}^{|Q|}$ 表示签到数据的集合, E 表示序列图中两个相邻节点之间的边集, 表示访问旅游兴趣点 P_r^u 后的下一个兴趣点为 P_{r+1}^u 。

为了进一步利用结构化 POI 的空间邻近性, 本文采用谱图卷积网络 (GCN), 该网络能够挖掘隐藏在图的拓扑信息中的非结构化信息。为了更好地捕捉 POI 与动态空间之间的相关性, 构建归一化拉普拉斯矩阵 L 的邻接矩阵, 式(7):

$$L = (D + I)^{-1}(A + I) \quad (7)$$

其中, D, A, I 分别表示度矩阵、邻接矩阵和单位矩阵。

每个卷积层只处理一阶邻域信息, 包括自度矩阵和对邻接矩阵的归一化运算, 则 GCN 的逐层传播规则被定义式(8):

$$H^{(l)} = \sigma(LH^{(l-1)} W^{(l)}) \quad (8)$$

其中, $H^{(l-1)}$ 是节点第 l 层的输出结果; $W^{(l)}$ 表示线性变换矩阵; σ 是非线性激活函数。

GCN 学习节点表示, 通过聚合邻接节点信息生成中间表示, 再经线性投影和非线性激活更新所有节点。

通过构建区域子图, 利用空间结构和地理特征将兴趣相似的用户分类。区域子图数可用集合 $R = \{r_1, r_2, \dots, r_i\}$ 表示, i 表示区域子图, 同类用户归入同一子图, 并将直接相连的 POI 也归入该子图。同一 POI 可能出现在多个子图中, 但每个用户只属于

一个子图。合并用户和 POI 的初始嵌入,通过一阶图卷积得到用户和 POI 的签到关系,本文将所有用户和 POI 的初始嵌入进行合并,并利用一阶图卷积运算进行处理,式(9)和式(10):

$$e_u^{(1)} = \sum_{i \in N_u} \frac{1}{\sqrt{|N_u|} \sqrt{|N_p|}} e_p^{(0)} \quad (9)$$

$$e_p^{(1)} = \sum_{u \in N_p} \frac{1}{\sqrt{|N_u|} \sqrt{|N_p|}} e_u^{(0)} \quad (10)$$

其中, N_u 表示用户访问的 POI 的集合; N_p 表示已经访问 POI 的用户的集合; $\frac{1}{\sqrt{|N_u|} \sqrt{|N_p|}}$ 用于实现对称归一化。

在图卷积中,用户节点归属一个子图,POI 分布在其相关的子图,POI 嵌入是所有含该 POI 的子图中嵌入之和。经 $l-1$ 层图卷积传播后得到,式(11)~式(13):

$$e_u^{(l)} = \sum_{pr \in N_u} \frac{1}{\sqrt{|N_u|} \sqrt{|N_p|}} e_{pi}^{(l-1)} \quad (11)$$

$$e_{pi}^{(l)} = \sum_{u \in N_p} \frac{1}{\sqrt{|N_u|} \sqrt{|N_p|}} e_u^{(l-1)} \quad (12)$$

$$e_p^{(k)} = \sum_{s \in R} e_{pi}^{(k)} \quad (13)$$

其中, R 为 POI 所在的每个区域子图的集合, e_{pi} 为 POI 在区域子图 r_i 中的嵌入表示。

2 实验结果及分析

2.1 数据集描述

基于位置的社交网络拥有大量用户数字足迹,用户通过签到分享位置。为验证融合时空信息个性化旅游兴趣点推荐算法的有效性,本文选用 Foursquare 和 Gowalla 这两个公开、广泛使用的 LBSN 数据集进行实验,数据集包含用户、POI、时间戳、经度、纬度等信息。数据处理时,删除了访问或登记次数少于 5 次的用户,并随机按 7:3 划分训练集和测试集。数据集信息见表 1。

表 1 数据集描述

Table 1 Description of the datasets

| 数据集 | 用户数 | 兴趣点数 | 签到数 |
|------------|--------|--------|-----------|
| Gowalla | 19 541 | 32 981 | 3 117 914 |
| Foursquare | 17 642 | 28 483 | 2 796 232 |

2.2 评估指标

为了评估模型的泛化能力,本文使用召回率 (Recall@K) 来衡量精准推荐的旅游兴趣点比例,用归一化折损累计增益 (Normalized Cumulative Loss

Gain, NDCG@K) 来衡量排名表现,并通过这两个指标来逐步优化提出的算法。召回率的计算公式(14):

$$Recall@K = \frac{S_K^u}{K} \quad (14)$$

其中, S_K^u 为用户感兴趣的 POI 个数。

归一化折损累计增益考虑了每个旅游兴趣点的实际相关性,式(15):

$$DGG@K = \sum_{i=1}^K \frac{2^{rel_i} - 1}{\log(i+1)} \quad (15)$$

IDCG 则表示推荐系统给某一用户返回的最好推荐结果列表,即最相关的结果(目标旅游兴趣点)放在最前面,式(16):

$$IDCG@K = \sum_{i=1}^{REL@K} \frac{2^{rel_i} - 1}{\log(i+1)} \quad (16)$$

其中, rel_i 表示位置 i 的推荐结果的相关性。

一般设置用户给出正反馈的旅游兴趣点的值为 1,其余旅游兴趣点的值为 0。

用每个用户的 DCG 与 IDCG 之比作为每个用户归一化后的分值,即 NDCG,使不同用户之间的 NDCG 值有可比性,式(17):

$$NDCG@K = \frac{DCG@K}{IDCG@K} \quad (17)$$

2.3 性能分析

为了验证本文提出的融合时空信息个性化旅游兴趣点推荐算法有效性,本文选取了 ST-GGNN^[14]、SR-GNN^[15]、ST-LSTM^[16] 等相关算法与本文提出的融合时空信息个性化旅游兴趣点推荐算法在两个公开的数据集上进行对比实验,实验结果见表 2。可见本文提出的推荐模型明显优于其它基线模型,本文提出的模型比最优的基线模型 ST-GGNN 在召回率 Recall@5、Recall@10、Recall@20 和归一化折损累计增益 NDCG@5、NDCG@10、NDCG@20 分别提高了 6.5%、31.9%、21.4%、24.1%、24.1%、40.8%,表明本文提出的方法能有效提升推荐性能。

为了更好地评估模型,本文基于所提出的方法,进行了消融实验,分别去除了时空特征捕获层 (Ours-TD) 和区域子图 (Ours-R) 用来评估所提出的模型中的核心部分对实验性能的影响,实验结果如图 1 和图 2 所示,可见去除了时空特征捕获层 (Ours-TD) 和区域子图设置模块 (Ours-R),算法都表现出了较弱的性能,说明了这两种设计所包含的组件在一定程度上都有助于获取用户的偏好。

表 2 模型精度对比表

Table 2 Comparison of model accuracy

| 算法 | Gowalla 数据集 | | | | | |
|---------|-------------|------------|------------|---------|----------|----------|
| | Recall@ 5 | Recall@ 10 | Recall@ 20 | nDCG@ 5 | nDCG@ 10 | nDCG@ 20 |
| SR-GNN | 0.044 3 | 0.049 8 | 0.053 1 | 0.044 7 | 0.050 1 | 0.056 8 |
| ST-LSTM | 0.055 2 | 0.064 2 | 0.078 3 | 0.056 9 | 0.059 4 | 0.066 7 |
| ST-GGNN | 0.069 9 | 0.089 1 | 0.133 5 | 0.064 3 | 0.072 6 | 0.077 3 |
| Ours | 0.074 5 | 0.117 6 | 0.162 1 | 0.079 8 | 0.090 1 | 0.108 9 |

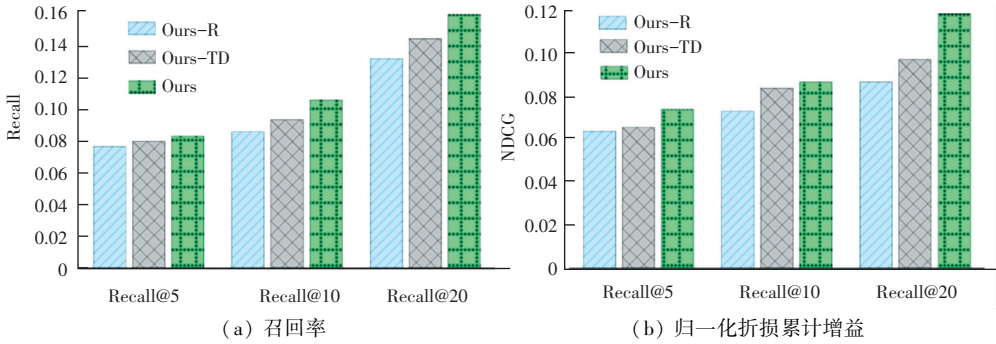


图 1 在 Gowalla 数据实验结果

Fig. 1 The results of experiments in Gowalla data




图 2 在 Foursquare 数据实验结果

Fig. 2 The results of experiments in Foursquare data

3 结束语

现有算法忽略了时空信息和空间相关性,而用户的空间偏好可从签到序列中推断。本文提出了融合时空信息个性化旅游兴趣点推荐算法,获取用户动态信息,参与领域信息聚合,捕捉时空相关性,动态更新序列图节点,提供用户可能感兴趣的下一个旅游 POI 列表。在两个公开的社交网站的数据上进行了实验验证,实验结果表明此方法提升了推荐性能,为个性化旅游推荐提供了一定的借鉴。

参考文献

[1] LIU X, LIU Y, ABERER K, et al. Personalized point-of-interest recommendation by mining users' preference transition [C]// Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. 2013: 733-738.

[2] VEGETABLE B G, STOUT-OSWALD S A, DAVIS E P, et al.

Estimating the entropy rate of finite Markov chains with application to behavior studies [J]. Journal of Educational and Behavioral Statistics, 2019, 44(3): 282-308.

[3] QI L, LIU Y, ZHANG Y, et al. Privacy-aware point-of-interest category recommendation in internet of things[J]. IEEE Internet of Things Journal, 2022, 9(21): 21398-21408.

[4] RAHMANI H A, ALIANNEJADI M, AHMADIAN S, et al. LGLMF: local geographical based logistic matrix factorization model for POI recommendation[C]//Proceedings of the 15th Asia Information Retrieval Societies Conference on Information Retrieval Technology, AIRS 2019. Hong Kong, China: Springer International Publishing, 2020: 66-78.

[5] XU Z, HU Z, ZHENG X, et al. A matrix factorization recommendation model for tourism points of interest based on interest shift and differential privacy [J]. Journal of Intelligent & Fuzzy Systems, 2023 (Preprint): 1-15.

[6] WANG Q, YIN H, CHEN T, et al. Next point-of-interest recommendation on resource-constrained mobile devices [C]// Proceedings of the Web Conference 2020. 2020: 906-916.