

一种基于图注意力聚合的POI推荐新方法

蔡国永, 陈心怡, 王顺杰

引用本文

蔡国永, 陈心怡, 王顺杰. 一种基于图注意力聚合的POI推荐新方法[J]. 计算机科学, 2022, 49(11A): 210800149-5.

CAI Guo-yong, CHEN Xin-yi, WANG Shun-jie. [Novel Method Based on Graph Attentive Aggregation for POI Recommendations](#) [J]. Computer Science, 2022, 49(11A): 210800149-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于依赖联系分析的观点词对协同抽取](#)

Opinion Word-pairs Collaborative Extraction Based on Dependency Relation Analysis
计算机科学, 2020, 47(8): 164-170. <https://doi.org/10.11896/jsjx.190600153>

[融合多层语义的跨模态检索](#)

Cross-modal Retrieval Fusing Multilayer Semantics
计算机科学, 2019, 46(3): 227-233. <https://doi.org/10.11896/j.issn.1002-137X.2019.03.034>

[一种提高推荐多样性的概率选择模型](#)

Improving Recommendation Diversity via Probabilistic Selection
计算机科学, 2016, 43(2): 72-77. <https://doi.org/10.11896/j.issn.1002-137X.2016.02.016>

[基于LT⁺模型的社交网络影响力最大化研究](#)

Influence Maximization Based on LT⁺ Model in Social Networks
计算机科学, 2016, 43(9): 99-102. <https://doi.org/10.11896/j.issn.1002-137X.2016.09.018>

[基于功能匹配分解的协议转换器构造技术研究](#)

计算机科学, 2003, 30(10): 117-119.

一种基于图注意力聚合的 POI 推荐新方法

蔡国永 陈心怡 王顺杰

桂林电子科技大学计算机与信息安全学院 广西 桂林 541000

广西可信软件重点实验室(桂林电子科技大学) 广西 桂林 541000

摘要 在基于位置社交网络(Location-based Social Network, LBSNs)的服务中,有效的兴趣点(Point-of-Interest, POI)推荐具有极大的经济和社会效用,但如何深入理解 LBSN 中的位置、结构和行为等相关信息,并进行推理以及实现 POI 推荐仍然是一项挑战性任务。针对 LBSNs 中的多种异构数据,提出了一种能够挖掘用户社交和 POI 多种特征信息的用于 POI 推荐的图神经网络模型——POIR-GAT。首先 POIR-GAT 利用社交关系构建用户-用户图,并结合用户-POI 交互图共同抽取用户特征向量;其次,基于 POI 的不同地理特征构造不同的特征矩阵,并通过矩阵分解获得不同的潜在因子,将这些潜在因子融入 POI 的特征向量,以学习它们对用户行为的共同影响,并用于实现融合社交因素和 POI 特征的推荐模型。通过在 2 个公开数据集上进行的实验,验证了所提 POIR-GAT 模型可以有效融合用户社交信息和 POI 特征信息,提高 POI 推荐质量。

关键词: LBSNs; POI 推荐; 图注意力神经网络; 特征矩阵分解

中图法分类号 TP391.3

Novel Method Based on Graph Attentive Aggregation for POI Recommendations

CAI Guo-yong, CHEN Xin-yi and WANG Shun-jie

College of Computer and Information Security, Guilin University of Electronic Technology, Guilin, Guangxi 541000, China

Key Laboratory of Guangxi Trusted Software(Guilin University of Electronic Technology), Guilin, Guangxi 541000, China

Abstract For services on location-based social network(LBSNs), effective point of interest(POI) recommendation has great economic and social utility. However, how to comprehend the position, structure and behavior related information of LBSNs and proceed reasoning for POI recommendation is still a challenge task. To exploit the heterogeneous information on LBSN, a novel graph attentive aggregation model for POI recommendation(POIR-GAT) is proposed, which exploits both users' social information and POIs' attributed information. Firstly, POIR-GAT uses social relationship to construct user-user graph, and extracts user feature vector together with user-POI interaction graph. Secondly, it constructs feature matrix based on different attributes of POIs, obtains hidden factors through matrix decomposition, integrates multiple features into POI feature vector, and learns their common influence on user behavior. Finally, it realizes the integration of social factors and POI features recommended model. Extensive experiments on two public datasets show that the proposed POIR-GAT model can effectively integrate users' social information and POI feature information, and improve the quality of POI recommendation.

Keywords LBSNs, POI recommendation, Graph attention neural network, Feature matrix decomposition

1 引言

用户可以通过在线平台轻松地在物理世界中共享其地理空间位置和与位置相关的内容,如带有地理标签的照片和笔记。我们将这些社交网络称为基于位置的社交网络(LBSNs)^[1]。LBSNs 中具有复杂的异构信息,这些信息在 POI 推荐中将发挥重要作用。大多数基于协同过程的推荐系统假设用户-POI 的交互是相互独立的,满足独立同分布假设。然而,在 LBSNs 中,用户之间、POI 点之间都存在关联,这种交互的独立性假设并不成立。如何利用这些依赖信息来提升

推荐性能,需要提出新的推荐算法。

近年来,处理依赖数据的图神经网络(Graph Neural Networks, GNNs)得到高度关注^[2]。GNNs 自然地整合了节点信息和拓扑结构,并被证明在图表示学习方面具有强大的能力^[3-5]。LBSNs 中复杂的关联数据,可以利用 GNN 的优势抽取出更加有效的嵌入表示,从而可能提升 POI 推荐效果。然而,基于 GNN 构建 POI 推荐面临着挑战,例如,如何整合各类依赖图并抽取融合的特征等。针对这些问题,本文提出了一种基于 LBSNs 的用于 POI 推荐的图神经网络方法——POIR-GAT。POIR-GAT 能够融入 LBSNs 中的多种异构

基金项目:广西驱动重大专项基金(AA19046004);广西可信软件重点实验室项目(kx202060)

This work was supported by the Science and Technology Major Project of Guangxi Province(AA19046004) and Guangxi Key Lab of Trusted Software(kx202060).

通信作者:蔡国永(ccgycai@guet.edu.cn)

数据信息,包括用户社交信息和 POI 的多种特征信息,从而为用户提供性能更好的个性化 POI 推荐。

本文第 2 节介绍相关工作;第 3 节介绍提出的模型——POIR-GAT;第 4 节通过实验,分析本文所提模型的推荐性能;最后总结全文。

2 相关工作

大部分 POI 推荐研究采用传统协同过滤算法,利用用户和 POI 之间的历史交互信息,对用户和签到的 POI 进行建模,最后基于相似性进行推荐;也有研究者也提出基于矩阵分解的推荐方法。它们都是用一个潜在向量表征用户和 POI,用潜在向量间的内积表示用户和 POI 之间的交互可能性。文献[6]提出了一个统一的位置推荐协同过滤框架,该框架线性融合了用户兴趣和地理影响。还有一些研究聚焦于内容信息在推荐中的使用,如用户评论和兴趣点属性等在兴趣点推荐中的应用。文献[7]提出了一种新的位置内容感知的概率生成模型,该模型量化并结合了用于 POI 推荐的本地偏好和 POI 内容信息。文献[8]提出了一种利用用户和兴趣点之间的地理、社会和分类关联的用户兴趣点推荐方法。这些 POI 推荐方法因考虑到了 POI 相关的属性信息,一定程度上克服了传统协同过滤法的数据稀疏问题,但并没有很好地利用 LBSNs 中存在的重要且不容忽视的社交信息。

近年来,利用社会关系进行推荐得到了关注。文献[9]提出了一种共因子分解方法 SoRec,该方法共享一个共同的潜在用户特征矩阵,该矩阵通过评级和社会关系进行因子分解。

文献[10]中的 TrustMF 方法模拟了用户之间的相互影响,并通过分解社会信任网络将用户映射到两个低维空间。然而这些方法都没有跳出传统协同过滤和矩阵分解的桎梏,无法提供更有效的 POI 推荐。

随着深度学习的兴起,越来越多的研究者开始利用神经网络进行推荐。NeuMF^[11]给出了一个神经协同过滤框架来学习用户和项目之间的非线性交互。DeepSoR^[12]将用户社会关系的神经网络集成到概率矩阵分解中,并首先使用预先训练的节点嵌入技术来表示用户,进一步利用 k 近邻来连接用户嵌入特征和神经网络。Liu 等^[13]提出了一个空间-时间神经网络的 POI 推荐模型,该模型添加了一个特定时间和特定距离的转换矩阵,以捕获时间和地理影响。文献[14]提出了一个类别感知深度模型,该模型预测用户在未来 24 h 内将访问的 POI。Christoforidis 等^[15]提出了一种联合学习图嵌入方法,从 6 个信息图中联合学习用户和 POI 在同一空间的向量表示。尽管这些工作取得了令人瞩目的成果,但是目前在 POI 推荐中能全面有效利用 LBSN 中丰富且复杂的异构数据的模型并不多,而 GNN 展示了这种可能性。本文将 LBSNs 中的多种关联信息构建为多种图,基于 GNN 来抽取多种特征信息,得到用户表示和 POI 表示,从而能更有效地进行 POI 推荐。

3 POIR-GAT 模型介绍

首先表 1 中列出了文中使用的符号及其含义,然后详细介绍所提出的 POIR-GAT 模型。

表 1 数学符号及其含义

Table 1 Mathematical symbols and their meaning

符号	含义	符号	含义
q_a	POI a 的初始嵌入向量	z_v^O	POI v 的共访潜在因子
p_i	用户 i 的初始嵌入向量	G	地理临近矩阵
$C(i)$	与用户 i 交互的 POI 集	z_v^G	POI v 的地理临近潜在因子
$N(i)$	用户 i 的社交好友集	C	类别相关矩阵
$B(j)$	与目标 POI j 交互的用户集	z_v^C	POI v 的类别相关潜在因子
h_i	用户 i 的特征向量	\oplus	两个向量的连接运算符
h_i^l	用户 i 的 POI 潜在因子	α_{ia}	用户 i 与 POI a 交互的注意力权重
z_j	POI j 的特征向量	μ_{jt}	POI j 与用户 t 交互的注意力权重
z_j^U	POI j 的潜在因子	W, b	神经网络中的权重和偏置
O	共同访问矩阵	h_i^S	用户 i 的社交潜在因子
β_{iv}	用户之间关系强度的注意权重		

模型 POIR-GAT 由用户表示学习、POI 表示学习和推荐评分预测 3 个模块组成。用户建模用于学习用户的特征向量表示。LBSNs 中的数据中显式包含了用户-用户关系图和用户-POI 交互图,可以通过用户-用户图从社交角度获得用户潜在因子,通过考虑用户与 POI 之间的交互从行为角度获得用户潜在因子,然后将这两者结合起来获得用户特征表示。POI 表示学习使用基于矩阵分解的特征嵌入方法,同时融合 POI 的共同访问、地理临近和类别这 3 个特征信息以获得 POI 特征表示,并缓解 POI 推荐中的数据稀疏问题。推荐评分预测模块将用户特征表示和 POI 特征表示连接起来作为输入,获得目标用户-POI 对的预测分数。图 1 为 POIR-GAT 的整体框架图,其中的一些符号见表 1 及下文中的介绍。




图 1 POIR-GAT 的整体框架

Fig. 1 Overall framework of POIR-GAT

3.1 用户表示学习

用户表示学习的目的是学习用户的特征向量 \mathbf{h}_i , 主要从用户-用户社交图和用户-POI 访问图这两个图数据来学习, 使用了基于图注意力的聚合机制。第一种聚合为 POI 聚合, 从用户与 POI 之间的交互中学习用户的 POI 潜在因子 \mathbf{h}_i^l ; 第二种聚合为社交聚合, 从用户-用户图中学习用户的社交潜在因子 \mathbf{h}_i^s 。然后将这二者连接在一起, 获得最后的用户特征向量 \mathbf{h}_i 。

POI 聚合: POI 聚合的目的是通过考虑用户交互过的 POI 来获得用户的 POI 潜在因子 \mathbf{h}_i^l , 可表示为:

$$\mathbf{h}_i^l = \sigma(\mathbf{W} \cdot \text{Agg}_{\text{items}}(\{\mathbf{q}_a, \forall a \in C(i)\}) + b) \quad (1)$$

其中, $C(i)$ 表示与用户 i 交互的 POI 集, \mathbf{q}_a 是由文献[16]提出的方法获得的 POI a 的初始嵌入向量, \mathbf{W} 和 b 是神经网络的权值和偏置, $\text{Agg}_{\text{items}}$ 表示 POI 聚合函数, 其定义如式(2)所示:

$$f_{\text{Agg}_{\text{items}}} = \sum_{a \in C(i)} \alpha_{ia} \mathbf{q}_a \quad (2)$$

其中, α_{ia} 表示用户 i 与 POI a ($a \in C(i)$) 交互的注意力权重。这里用一个两层神经网络(称为注意力网络)来参数化 α_{ia} , 其定义如式(3)所示:

$$\alpha_{ia}^* = \mathbf{w}_i^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{q}_a \oplus \mathbf{p}_i] + b_1) + b_2 \quad (3)$$

利用 Softmax 函数对上述注意力得分进行归一化处理, 得到最终的注意力权重, 如式(4)所示:

$$\alpha_{ia} = \frac{\exp(\alpha_{ia}^*)}{\sum_{a \in C(i)} \exp(\alpha_{ia}^*)} \quad (4)$$

因此, \mathbf{h}_i^l 表示变换成如式(5)所示:

$$\mathbf{h}_i^l = \sigma(\mathbf{W} \cdot \{\sum_{a \in C(i)} \alpha_{ia} \mathbf{q}_a\} + b) \quad (5)$$

社交聚合: 社交聚合的目的是通过用户-用户交互图来获得用户的社交潜在因子 \mathbf{h}_i^s 。根据社会学相关理论^[16], 用户的偏好与其直接联系的社交朋友存在相似性。因此, 通过对用户社交朋友信息进行聚合, 得到用户的社交潜在因子 \mathbf{h}_i^s , 其表达式如式(6)所示:

$$\mathbf{h}_i^s = \sigma(\mathbf{W} \cdot \text{Agg}_{\text{neigh}}(\{\mathbf{h}_o \in N(i)\}) + b) \quad (6)$$

其中, $N(i)$ 表示用户 i 的社交好友集。 \mathbf{W} 和 b 是神经网络的权值和偏置。 $\text{Agg}_{\text{neigh}}$ 表示社交聚合函数, 其定义如式(7)所示:

$$f_{\text{Agg}_{\text{neigh}}} = \sum_{o \in N(i)} \beta_{io} \mathbf{h}_o \quad (7)$$

其中, β_{io} 表示用户之间关系强度的注意力权重。在社交网络中, 强弱关系是混合在一起的, 根据现实社交经验, 用户更喜欢强关系。为了反映出强弱关系对用户的潜在因子做出了不同的贡献, 对不同关系赋予不同的权重。同样使用两层神经网络来参数化, 定义如式(8)所示:

$$\beta_{io}^* = \mathbf{w}_i^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{h}_i^l \oplus \mathbf{p}_i] + b_1) + b_2 \quad (8)$$

利用 Softmax 函数对上述注意得分进行归一化处理, 得到最终的注意权重:

$$\beta_{io} = \frac{\exp(\beta_{io}^*)}{\sum_{o \in N(i)} \exp(\beta_{io}^*)} \quad (9)$$

因此, \mathbf{h}_i^s 表示如式(10)所示:

$$\mathbf{h}_i^s = \sigma(\mathbf{W} \cdot \{\sum_{o \in N(i)} \beta_{io} \mathbf{h}_o\} + b) \quad (10)$$

为了更好地得到用户的向量表示, 需要将用户的 POI 潜在因子 \mathbf{h}_i^l 和用户的社交潜在因子 \mathbf{h}_i^s 结合起来, 因为用户-用户图和用户-POI 图从不同的角度提供了关于用户的信息。因此, 我们首先将 \mathbf{h}_i^l 和 \mathbf{h}_i^s 连接起来, 然后将其与用户当前

嵌入 \mathbf{p}_i 聚合合并成一个向量, 即为最终的用户向量表示。最终的用户向量表示 \mathbf{h}_i 为:

$$\mathbf{h}_i = \sigma(\mathbf{W} \cdot [\mathbf{p}_i \oplus (\mathbf{h}_i^l \oplus \mathbf{h}_i^s)] + b) \quad (11)$$

3.2 POI 表示建模

POI 建模的目的是学习 POI 的特征向量 \mathbf{z}_j , 从 LBSN 网中用户-POI 图学习 POI 的潜在因子 \mathbf{z}_j^U , 同时使用基于矩阵分解的特征嵌入方法; 此外, 对 LBSN 网中 POI 的其他多个特征信息进行学习, 如这里考虑了 POI 的共同访问、地理临近和类别这 3 类特征信息, 其他更多特征信息可进行类似的处理。

POI 的潜在因子 \mathbf{z}_j^U 学习: 通过用户-POI 图获得 POI 的潜在因子 \mathbf{z}_j^U , 表达式如式(12)所示:

$$\mathbf{z}_j^U = \sigma(\mathbf{W} \cdot \text{Agg}_{\text{user}}(\{\mathbf{p}_t, \forall t \in B(j)\}) + b) \quad (12)$$

其中, $B(j)$ 表示与目标 POI j 交互过的用户集合, \mathbf{p}_t 是由文献[11]提出的方法获得的用户的初始嵌入向量。 \mathbf{W} 和 b 是神经网络的权值和偏置。 $\text{Agg}_{\text{users}}$ 为聚合函数, 其定义如式(13)所示:

$$f_{\text{Agg}_{\text{user}}} = \sum_{t \in B(j)} \mu_{jt} \mathbf{p}_t \quad (13)$$

其中, μ_{jt} 表示 POI j 与用户 t ($t \in B(j)$) 交互的注意权重。这里同样用一个两层神经网络来参数化 μ_{jt} , 其定义如式(14)所示:

$$\mu_{jt}^* = \mathbf{w}_j^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{q}_j \oplus \mathbf{p}_t] + b_1) + b_2 \quad (14)$$

利用 Softmax 函数对上述注意力得分进行归一化处理, 得到最终的注意权重:

$$\mu_{jt} = \frac{\exp(\mu_{jt}^*)}{\sum_{t \in B(j)} \exp(\mu_{jt}^*)} \quad (15)$$

因此, \mathbf{z}_j^U 表示如式(16)所示:

$$\mathbf{z}_j^U = \sigma(\mathbf{W} \cdot \{\sum_{t \in B(j)} \mu_{jt} \mathbf{p}_t\} + b) \quad (16)$$

POI 的其他特征信息学习: 考虑到 POI 的各种特征对用户行为的影响, 同时解决数据稀疏问题, 我们利用 LBSN 网中 POI 的 ID、地理坐标和所属类别这 3 个特征信息, 分别构建 POI 共同访问矩阵、地理临近矩阵和类别相关矩阵, 并在这 3 个矩阵上采用基于 MF 的特征嵌入技术, 获得 POI 在共访、地理和类别特征空间中对应的嵌入向量, 并将所得隐向量拼接成为一个整体的 POI 特征向量表示。详细描述如下:

(1) 共同访问矩阵 \mathbf{O} 及其分解: 引入一个 POI 共访矩阵, 表示 POI 在用户访问行为上的关联关系。该矩阵的元素 O'_{vv} 表示同时访问过 POI v 和 v' 的用户的个数, 对角线元素 O_{vv} 表示访问 v 的用户个数。 O'_{vv} 值越大, 表明 v 和 v' 频繁地被先后访问, 就可以证明其关联性越强。

由于共访矩阵 \mathbf{O} 是对称的, 采用非负对称矩阵分解将 \mathbf{O} 分解为低秩潜在因子矩阵 \mathbf{E}_O 及其转置这两个矩阵的点乘, 如式(17)所示:

$$\min_{\mathbf{E}_O} \|\mathbf{O} - \mathbf{E}_O \mathbf{E}_O^T\|_F^2 + \lambda_o \|\mathbf{E}_O\|_F^2 \quad (17)$$

其中, $\|\cdot\|_F$ 表示矩阵的 Frobenius 范数, λ_o 为正正则项参数。完成分解之后, \mathbf{E}_O 中的每一行都是该 POI v 的共访潜在因子, 表示为 \mathbf{z}_v^O 。

(2) 地理临近矩阵 \mathbf{G} 及其分解: 与共同访问矩阵 \mathbf{O} 相似, 构建一个地理临近矩阵 \mathbf{G} , 表示用户的签到行为和 POI 的地理位置相关联。通过引入距离阈值 m , 若 v 和 v' 互通的路线距离小于 m , 则 G'_{vv} 为 1, 否则 G'_{vv} 为 0。采用同样的分解方法, 将式(18)作为分解优化目标函数:

$$\min_{E_C} \|O - E_G E_C^T\|_F^2 + \lambda_G \|E_G\|_F^2 \quad (18)$$

其中, λ_G 为正则项参数。完成分解后, E_G 中的每一行都是该 POI v 的地理临近潜在因子, 表示为 z_v^G 。

(3) 类别矩阵 C 及其分解: 构建一个类别关联矩阵 C , 表示 POI 在类别信息上的关联, 该矩阵利用了 POI 的内容信息。当 POI v 和 v' 属于同一个类别时, $C_{vv'}$ 为 1, 否则 $C_{vv'}$ 为 0。类似地采用式(19)对其进行分解。

$$\min_{E_C} \|O - z_c E_C^T\|_F^2 + \lambda_C \|E_C\|_F^2 \quad (19)$$

其中, λ_C 为正则项参数。完成分解后, E_C 中的每一行都是该 POI v 的类别相关潜在因子, 表示为 z_v^C 。

为了更好地得到 POI 的特征向量, 首先将分解得到的 3 种特征的潜在因子拼接成为一个整体的 POI 特征向量表示 z_j^F , 如式(20)所示:

$$z_j^F = [z_v^O z_v^G z_v^C] \quad (20)$$

然后将其与从用户-POI 图中学习到的 POI 的潜在因子 z_i^U 融合成一个最终 POI 向量 z_j , 如式(21)所示:

$$z_j = \sigma(W \cdot [z_i^U \oplus z_j^F] + b) \quad (21)$$

通过上述一系列操作, 既可以捕捉到用户与 POI 之间的交互, 又融合了 POI 的 3 种特征信息, 缓解了数据稀疏问题。

3.3 推荐评分预测

通过用户建模和 POI 建模, 得到了用户表示 h_i 和 POI 表示 z_j , 将其拼接起来作为输入 g , 并通过多层 MLP 获得用户-POI(i, j) 的预测评分, 如式(22)所示:

$$g_0 = [h_i \oplus z_j]$$

$$g_l = \sigma(W_l \cdot g_{l-1} + b_l) \quad (22)$$

$$\hat{y}_{ij} = \sigma'(W_o \cdot g_L + b_o)$$

通过如式(23)所示的目标函数来对模型进行训练优化:

$$Loss = -(\sum \sum y_{ij} \log(\hat{y}_{ij}) + (1 - y_{ij}) \log(1 - \hat{y}_{ij})) + \lambda \|F\|_2^2 \quad (23)$$

其中, F 表示所有可训练模型参数, λ 防止过拟合。

4 实验评估

4.1 实验数据

POIR-GAT 模型实验评估在两个公开的 LBSN 网络数据集上进行, 其一是 Foursquare 上东京的 POI 签到记录, 其二是 Gowalla 上纽约的 POI 签到记录。两个数据集上都移除了访问少于 3 个 POI 的用户和被访问少于 5 个用户的 POI, 预处理后的数据集统计如表 2 所列。

表 2 数据集统计

Table 2 Dataset Statistics

数据集	用户	POI	签到记录	类别
Foursquare	2293	7873	447.512	176
Gowalla	5426	8065	349.203	268

对于每个数据集, 随机选择每个用户 70% 的访问交互组成训练集, 再随机选择 10% 的访问交互作为验证集, 剩余的 20% 作为测试集。对于每个用户-POI 交互, 我们将其视为一个正例, 然后采用负采样策略, 将与用户不存在交互的 POI 作为一个负样配对。

4.2 评估指标

为了评估所提出的 POIR-GAT 模型的推荐质量, 采用了两种常用的度量方法来评估预测精度, 即平均绝对误差

(MAE) 和均方根误差 (RMSE)^[17]。MAE 和 RMSE 的值越小, 证明预测精度越高。实验中, 对所有模型进行 5 次重复试验, 然后取各指标的平均值。

4.3 对比方法

为了说明 POIR-GAT 模型的有效性, 将其与以下最先进的方法进行了比较。基线可以分为两类: 传统推荐方法 (PMF^[18], SoRec^[9], TrustMF^[10]) 和基于 GNN 的方法 (NeuMF^[11], DeepSoR^[12], GraphRec^[3])。简述如下:

(1) PMF: 概率矩阵分解。只利用用户项目评分矩阵, 通过高斯分布对用户和项目的潜在因素进行建模。

(2) SoRec: 对用户-项目评分矩阵和用户-用户社会关系矩阵进行因子分解。

(3) TrustMF: 采用矩阵分解技术, 将信任网络进行分解, 从而将用户表示映射到两个低维空间。

(4) NeuMF: 一种具有神经网络结构的矩阵分解模型。

(5) DeepSoR: 利用神经网络从社会关系中学习每个用户的表示, 并结合概率矩阵分解进行评分预测。

(6) GraphRec: 利用图神经网络从用户-项目图和社交图聚合信息以学习用户表示并进行推荐。

4.4 实验结果

在 Foursquare 数据集和 Gowalla 数据集上的实验结果分别如图 2 和图 3 所示。




图 2 Foursquare 数据集的实验结果

Fig. 2 Experimental results on Foursquare dataset




图 3 Gowalla 数据集的实验结果

Fig. 3 Experimental results on Gowalla dataset

从图 2 和图 3 的实验结果可以看出, POIR-GAT 模型在两个指标上都小于对比的基线方法, 说明了该模型有效提高了 POI 的推荐质量。这是由于 POIR-GAT 模型较好地综合学习利用了 LBSNs 网络中用户社交、POI 类别、邻近和共访矩阵等多种地理辅助信息, 更好地理解 LBSNs 中用户和 POI 的信息。

结束语 面向 LBSNs 中位置推荐的 POIR-GAT 模型, 本文提供了一种有效地结合 LBSNs 中的用户社交信息和 POI 多模态地理特征信息的方法; 既从用户-用户图和用户-POI 图两个视图数据学习用户表示, 又融合了 POI 的共同

访问、地理临近和类别这 3 种辅助特征信息。在两个真实数据集上的实验结果表明, POIR-GAT 的性能优于对比的代表性基线方法。实验也表明, 用户社交信息和 POI 的地理特征信息在提升推荐模型性能中起着重要的作用, LBSNs 中蕴含的这些辅助信息有利于缓解推荐系统中普遍存在的冷启动和数据稀疏问题。尽管 POIR-GAT 方法充分利用了图注意力神经网络的方法来融合各类关系信息, 提升了推荐效果, 但 LBSNs 中还蕴含哪些辅助信息, 或者对一些已讨论过的辅助信息是否要进行更精细的刻画, 特别是社交网络中个体的影响力、POI 的评论等信息对 POI 推荐的作用还值得进一步探讨。

参 考 文 献

- [1] BAO J, ZHENG Y, WILKIE D, et al. Recommendations in location-based social networks: A survey[J]. *GeoInformatica*, 2015, 19: 525-565.
- [2] WU Z H, PAN S R, CHEN F W, et al. A Comprehensive Survey on Graph Neural Networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(1): 4-24.
- [3] FAN W Q, MA Y, LI Q, et al. Graph Neural Networks for Social Recommendation[C]// *The World Wide Web Conference*. 2019: 417-426.
- [4] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering[C]// *Proceedings of the 30th International Conference on Neural Information Processing Systems*. 2016: 3844-3852.
- [5] TYLER D, MA Y, TANG J L. Signed Graph Convolutional Networks[C]// *2018 IEEE International Conference on Data Mining (ICDM)*. 2018: 929-934.
- [6] YE M, YIN P F, LEE W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation[C]// *International ACM Sigir Conference on Research & Development in Information Retrieval*. 2011: 325-334.
- [7] YIN H Z, SUN Y Z. LCARS: a location-content-aware recommender system[C]// *Proceedings of the 19th ACM SIGKDD*. 2013: 221-229.
- [8] LI H Y, GE Y. Point-of-interest recommendations: learning potential check-ins from friends[C]// *Proceedings of the 22th ACM SIGKDD*. 2016: 975-984.
- [9] MA H, YANG H X, MICHAEL R L, et al. Sorec: social recommendation using probabilistic matrix factorization[C]// *Proceedings of the 17th ACM Conference on Information and Knowledge Management*. 2008: 931-940.
- [10] YANG B, LEI Y, LIU J M, et al. Social collaborative filtering by trust[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(8): 1633-1647.
- [11] HE X N, LIAO L Z, ZHANG H W, et al. Neural Collaborative Filtering[C]// *Proceedings of the 26th International Conference on World Wide Web*. 2017: 173-182.
- [12] WANG X, HE X N, NIE L Q, et al. Item silk road: Recommending items from information domains to social users[C]// *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2017: 185-194.
- [13] LIU Q, WU S, WANG L, et al. Predicting the next location: A recurrent model with spatial and temporal contexts[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2016.
- [14] YU F Q, CUI L Z, GUO W, et al. A Category-Aware Deep Model for Successive POI Recommendation on Sparse Check-in Data[C]// *Proceedings of The Web Conference 2020*. 2020: 1264-1274.
- [15] CHRISTOFORIDIS G, KEFALAS P, PAPADOPOULOS A, et al. Recommendation of points-of-interest using graph embeddings[C]// *2018 IEEE 5th International Conference on Data Science and Advanced Analytics*. 2018: 31-40.
- [16] PETER V M, NOAH E F. Network studies of social influence[J]. *Sociological Methods & Research*, 1993, 22(1): 127-151.
- [17] WANG S H, TANG J L, WANG Y L, et al. Exploring Hierarchical Structures for Recommender Systems[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(6): 1022-1035.
- [18] MNIH A, SALAKHUTDINOV R. Probabilistic Matrix Factorization[C]// *21th Conference on Neural Information Processing Systems*. 2007: 1257-1264.



CAI Guo-yong, born in 1971, Ph.D, professor, Ph. D supervisor, is a senior member of China Computer Federation. His main research interests include social media mining, recommend system and sentiment analysis.