

一种基于图神经网络的社会化推荐算法

吕艳霞, 郝帅, 乔广通, 邢烨

(东北大学秦皇岛分校 计算机与通信工程学院, 河北 秦皇岛 066004)

摘要: 现有的社会化推荐算法大多着眼于用户购买或点击等单一的交互行为, 并未同时考虑收藏、浏览等多种不同的交互行为。而且当前的社会化推荐算法重点只关注推荐的准确性, 忽略了推荐结果的可解释性。针对以上问题, 提出了一种基于图神经网络的社会化推荐算法 SRGN, 将用户的社交关系和物品间客观存在的语义联系以特定的方式注入到算法架构中, 并且利用消息传递的方式实现交互的多行为联合编码, 从而提升推荐的准确性。此外, 设计了可解释模块为推荐结果提供推荐的理由。在两个真实数据集上与其他8种算法进行对比实验, 结果表明提出的算法在推荐性能和用户友好性上具有明显的优势。

关键词: 推荐系统; 社会化推荐; 图神经网络; 可解释推荐; 个性化推荐

中图分类号: TP 311 文献标志码: A 文章编号: 1005-3026(2024)01-0010-08

A Social Recommendation Algorithm Based on Graph Neural Network

LYU Yan-xia, HAO Shuai, QIAO Guang-tong, XING Ye

(School of Computer & Communication Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China. Corresponding author: LYU Yan-xia, E-mail: lyx@neuq.edu.cn)

Abstract: Most existing social recommendation algorithms focus on the user's single interaction such as purchase or click, but do not consider different interactions such as collection and browsing simultaneously. Moreover, current social recommendation algorithms only focus on the accuracy of recommendation, ignoring the interpretability of recommendation results. To solve the above problems, a social recommendation algorithm SRGN is proposed based on graph neural network, which injects the social relationships of users and the objectively existing semantic connections between items into the algorithm architecture in a specific way, and jointly encodes the interactive multi-behavior through message transmission, so as to improve the accuracy of recommendation. In addition, an explainable module is designed to provide reasons for the recommendation results. Compared with other eight algorithms on two real datasets, the results show that the proposed algorithm has obvious advantages in recommendation performance and user friendliness.

Key words: recommendation system; social recommendation; graph neural network; explainable recommendation; personalized recommendation

近年来,旨在利用用户的社交信息来推断用户偏好的社会化推荐受到了广泛关注^[1]。伴随信息技术和互联网的蓬勃发展,以Facebook、微信等全球性社交平台为代表的社交媒体日益壮大,用户之间的社交关系对用户在各种应用场景中的交互行为和决策产生了重要的影响。因此,利用社交关系提高推荐性能引起了越来越多的关注。

当前主流的社会化推荐算法,是通过学习一个嵌入函数,将用户的社交关系整合到用户和物品的嵌入表示中,进而借助神经网络计算推荐结果^[2]。这类方法虽然取得了不错的效果,但是仍然存在信息利用不充分的问题,比如仅仅挖掘用户与商品间单一类型的交互关系^[3],如购买、点击等,这与现实中交互行为的多样性不符。以电子商

收稿日期: 2022-07-22

基金项目: 国家自然科学基金资助项目(61901099); 河北省自然科学基金资助项目(F2021501020)。

作者简介: 吕艳霞(1982-),女,河北秦皇岛人,东北大学秦皇岛分校副教授。

为例,用户的购买、收藏、点击等多种交互行为都是用户偏好的外在表现,对这些交互行为进行有效联合编码能够更准确地推断用户的复杂兴趣。

此外,大多数社会化推荐算法仅仅着眼于用户间存在的社交关系,而忽视了物品之间客观存在的语义联系。在现实场景中,物品之间通常存在各种联系,这些联系表明了物品之间的语义关联,利用这些关联信息有助于更好地理解用户的交互行为模式。以线上销售平台为例,相同类别的商品,如照相机和计算机及其配套使用的其他商品,再比如手机和耳机、铅笔和橡皮等都存在客观的语义关联信息。然而,目前大多数社交推荐算法都没有考虑这种关联信息。

研究表明,若推荐系统能在给出符合用户兴趣的推荐结果的同时解释其推荐的原因,帮助用户作出更好的决策,将会显著提升用户的满意度与信任度,增加推荐系统的说服力与满意度。因此,在社会化推荐算法中对推荐结果进行合理的解释也是一项重大挑战。深度学习模型在社会化推荐算法中的大规模应用,在带来性能提升的同时也造成模型的黑盒子特性,即决策过程的不透明性,也增加了理解推荐系统行为的难度。大多数基于社交关系的推荐算法并未充分利用社交网络中的关系信息推断推荐结果的由来,如 TrustSVD^[4] 算法仅仅利用最直接的信任关系作为辅助信息进行推荐任务,而没有对社交关系信息做进一步挖掘。由于当前主流的推荐算法如 KGAT^[5] 等,均使用嵌入表示向量来表征用户和物品,无法从中获取直观的信息,这增加了算法直接对推荐结果进行解释的难度。

社交推荐系统中的社交关系图 and 用户-物品交互图从不同角度提供了用户信息。社交推荐的自然方式是将社交网络信息合并到用户和物品的表示学习中,学习物品和用户的表示是构建社交推荐算法的关键。图神经网络(GNN)利用神经网络迭代聚合来自局部图邻域的特征信息,自然地整合节点信息和拓扑结构,被证明在表示学习中具有强大的能力^[6]。基于以上讨论,本文提出了基于图神经网络的具有社交关系感知的社会化推荐算法(SRGN)。不仅考虑了交互的多行为异构性,能够同时捕捉物品之间的语义关联和用户间的社交关系,而且在推荐结果产生之后,针对每个推荐结果探索其在用户和物品关系信息中的路径关系,进而对推荐结果作出基于上述社交关系的推理。最后,在两个真实数据集上进

行了大量实验,结果表明本文提出的算法提高了推荐性能,同时实现了用户友好的推荐。

1 相关工作

1.1 社会化推荐

随着深度学习模型在推荐系统中的大规模使用,越来越多以神经网络为基础的推荐模型相继问世,例如 SAMN 模型^[7]通过注意力网络学习用户节点和邻居节点间的相互作用,EATNN^[8]模型采用自适应迁移神经网络作为核心架构等。在此基础上,近年来部分研究人员希望将用户的社交关系引入推荐系统,用以丰富用户的嵌入表示。其理论基础是同质效应,指人们倾向于认为特定群体成员具有更加固定、刻板的特征,成员间具有更多的相似性和更少的变异性。如 DANSER^[9]和 GraphRec^[10]等算法均利用图神经网络学习对用户的社交关系进行编码从而实现用户社交关系的嵌入。与这些方法不同,本文在引入用户的社交关系的基础上进一步融合了物品间的语义联系和交互的多行为模式,学习用户和物品的表示,从而提升推荐性能。

1.2 图神经网络

近年来,针对图数据的深度神经网络技术得到了巨大的发展,社会化推荐中的用户-物品交互数据和用户社交关系都可以表示为图数据,图神经网络为社会化推荐提供了前所未有的机会。PinSage^[11]和 NGCF^[12]利用交互图聚合节点自身和邻近多跳邻居节点的信息作为每个实体节点的最终嵌入表示。在此基础上,为了探索更加高效的图神经网络范式,LightGCN^[13]和 LRGCCF^[14]相继出现,前者取消了如激活函数等非必要组件,简化 GCN 的设计以提升效率;后者提出了一种新的残差网络结构,缓解了图卷积聚合操作中的过度平滑问题进而提高效率。受到以上研究的启发,本文设计了一种新的耦合图神经网络,联合编码用户的社交关系和物品间的语义联系,进而能够在保证节点自身独立性的前提下增强用户和物品的嵌入表示能力。

1.3 可解释性

在实际应用中,缺少解释性的推荐系统和算法难以提供具有说服力的推荐结果,用户无法理解为什么会被推荐这些内容,从而降低对系统的信任度。在实际应用中,推荐结果的解释主要分为后处理(Post-hoc)方法^[15]和嵌入式(Embedded)方法^[16]。前者是从推荐结果入手,在算法中增加

解释模块,推理出生成推荐结果的可能原因;后者把可解释融入到推荐算法的构建中,解释性较高,但是解释之间的连贯性和一致性无法保证,导致用户体验较差.以可解释为目标的新一代个性化社交推荐系统既要考虑提高算法的准确性,又要兼顾可解释性,本文实现了一种后处理解释方法为推荐结果提供解释.

2 问题定义

考虑一个典型的推荐场景,其中有数量为 I 的用户构成的用户集 $U = \{u_1, u_2, \dots, u_i, \dots, u_I\}$ 和数量为 J 的物品构成的物品集 $V = \{v_1, v_2, \dots, v_j, \dots, v_J\}$,为了捕捉多行为交互信息,算法定义用户与物品有 K 种交互行为,编码 $\{1, 2, \dots, k, \dots, K\}$.

1) 用户社交图. $G_u = \{U, E_u\}$ 定义为用户之间的社交关系. 其中 U 表示用户节点, E_u 为两个具有社交关系的用户节点 U_i 和 U_j 之间的连接线,用来表示两个用户间的社交关系,本文将用户的社交系统一定义为社交推荐中广泛采用的“朋友”关系.

2) 物品关系图. $G_v = \{V, E_v\}$ 定义为物品间的社交关系,即物品间的语义联系. 本文使用一个三元组 $\{v_j, e_{j,j'}, v_j | v_j, v_{j'} \in V\}$ 表示这种联系,其中 v_j 和 $v_{j'}$ 表示物品实体节点,而节点间的边 $e_{j,j'}$ 表示两个物品存在的各类关系. 例如 v_j 和 $v_{j'}$ 属于相同类别的产品,拥有相似的功能,或者是功能互补的产品.

3) 多行为交互图. $G_r = \{u_i, e_k, v_j | i \in I, j \in J, k \in K\}$ 定义为用户和物品间的多种交互行为. 其中边 e_k 表示用户节点 u_i 和物品节点 v_j 间的第 k 种交互行为,记为 $e_k = k$,否则记为 $e_k = 0$. 推荐任务被定义为由输入和输出组成,其中,输入为 G_u, G_v 和 G_r ,输出为预测函数 $f(G_u, G_v, G_r)$. 将用户社交图和物品关系图以及多行为交互图作为输入,计算并输出一个预测值,该值估计用户对特定物品的偏好. 同时根据输入和对应的输出在 3 个图中进行关系推理,为用户提供推荐结果的合理解释.

3 SRGN 算法

图 1 展示了本文提出的基于 GNN 的社交推

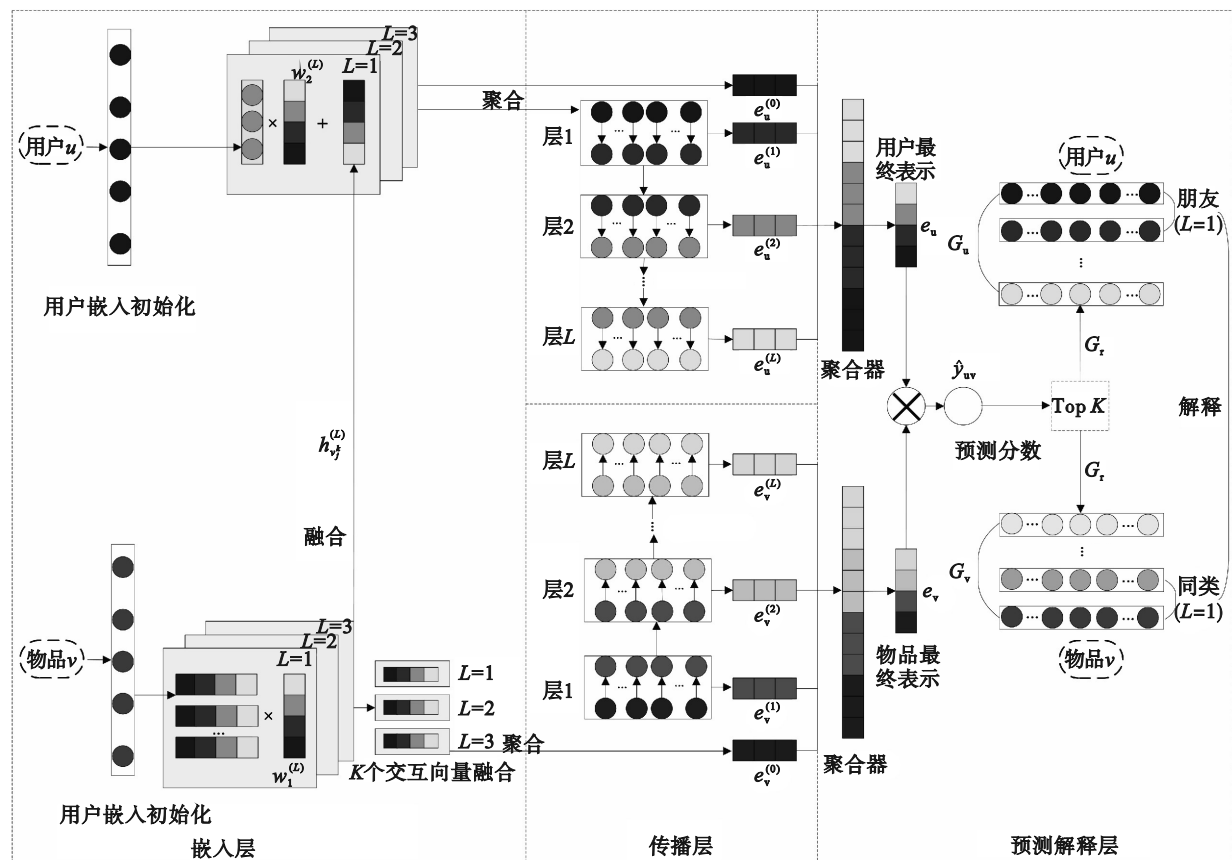


图 1 SRGN 算法总体结构图

Fig. 1 Overall structure of the SRGN

荐算法 SRGN 的总体框架,主要由嵌入层、传播层和预测解释层 3 个部分组成.

1) 嵌入层. 嵌入层主要利用 G_r 图进行嵌入表示学习,由用户嵌入表示学习和物品嵌入表示学习两部分组成. 用户和物品的 ID 信息作为用户和物品最原始的嵌入表示,使模型能够区分不同的用户和物品.

步骤 1 算法采用消息传递的方式进行物品嵌入表示学习,捕获不同类型的交互行为信息. 首先,用户交互信息被传递到物品嵌入表示中,即在 G_r 图中以物品节点为中心,独立计算 K 种异构行为的高阶聚合过程,进而利用平均聚合的方法融合 K 个嵌入表示向量生成最终的节点嵌入表示:

$$h_{v_j}^{(L+1)} = \sigma \left(\frac{|N_{v_j}^k|}{D} h_{v_j}^{(L)} w_1^{(L)} \right), \quad (1)$$

$$h_{v_j}^{(L)} = \text{mean} \left(\sum_{k=1}^K h_{v_j}^{(L)} \right). \quad (2)$$

其中: $\sigma(\cdot)$ 为 ReLU 函数;第 L 层的权重矩阵为 $w_1^{(L)}$, $L=0, 1, \dots$; $N_{v_j}^k$ 表示物品 v_j 与相连接的用户节点间交互行为为 k 的交互数量; $D = \sum_{k=1}^K N_j^k$ 表示 K 种交互行为总数. SRGN 能够捕获来自不同用户的多种交互行为模式,从而增强用户嵌入的表示能力,提升推荐效果.

步骤 2 算法在 G_r 图中同样采用消息传递的方法进行用户表示学习,用户初始化为用户 ID,即 $h_{u_i}^{(0)}$ 由两部分组成:第一部分为用户节点的自聚合操作,这样可以保证节点本身的特征不会减弱或消失;第二部分为信息传递,将用户有过交互行为的物品所含的异构行为信息融入到用户嵌入表示的生成过程有利于提升用户嵌入表示的准确性.

$$h_{u_i}^{(L+1)} = \sigma \left(\frac{1}{|N_{u_i}|} h_{u_i}^{(L)} w_2^{(L)} + \sum_{(j,k) \in N_{u_i}} \frac{1}{|N_{v_j}^k|} h_{v_j}^{(L)} w_1^{(L)} \right). \quad (3)$$

其中: N_{u_i} 表示 G_r 图中用户 u_i 的相邻节点数; $N_{v_j}^k$ 表示物品 v_j 已连接用户节点中交互类型为 k 的节点数; w_1, w_2 为权重矩阵. 算法为每一层学习结果分配一定权重分数,通过如下聚合操作生成用户/物品的嵌入表示:

$$h_{v_j} = \sum_{j=0}^L \frac{1}{L+1} h_{v_j}^{(L+1)}, \quad (4)$$

$$h_{u_i} = \sum_{i=1}^L \frac{1}{L+1} h_{u_i}^{(L+1)}. \quad (5)$$

2) 传播层. 传播层是聚合用户的社交关系和物品语义联系的结构,目的是将这些关系嵌入

到用户和物品的嵌入表示中以丰富其语义信息. 用户和物品的关系图 G_u 和 G_v 中连接实体具有强相关性,沿着关系路径聚合可以得到不同的扩展关系,从而增强用户和物品的语义表达. 用户 u_i 和物品 v_j 在关系图 G_u 和 G_v 上传播的定义为

$$e_{u_i}^{(L+1)} = \left\{ \sigma \left(e_{u_i}^{(L)} \cdot D_u^{-\frac{1}{2}} A_u D_u^{-\frac{1}{2}} \right) \middle| \{u_i, e_{u_i}, u_i\} \in G_u \right\}, \quad (6)$$

$$e_{v_j}^{(L+1)} = \left\{ \sigma \left(e_{v_j}^{(L)} \cdot D_v^{-\frac{1}{2}} A_v D_v^{-\frac{1}{2}} \right) \middle| \{v_j, e_{v_j}, v_j\} \in G_v \right\}. \quad (7)$$

其中: $D_u^{-\frac{1}{2}} A_u D_u^{-\frac{1}{2}}$ 为对称归一化项; $e_{u_i}^{(0)} = h_{u_i}$, $e_{v_j}^{(0)} = h_{v_j}$, 分别表示传播层初始用户和物品嵌入表示.

因为相邻实体间的关系可以视为用户或物品特征的直观扩展,利用这些关系图构建算法非常有意义. 通过嵌入层获得的初始嵌入类似于声波源,在关系图 G_u 和 G_v 中由近到远逐层传播. 通过基于关系的深度传播,成功地获取了用户和物品的高阶关系信息,有效地增强了用户和物品的语义表示能力. 与嵌入层相似,通过以下聚合操作来生成最终的嵌入表示:

$$e_{u_i} = \sum_{i=1}^L \frac{1}{L+1} e_{u_i}^{(L+1)}, \quad (8)$$

$$e_{v_j} = \sum_{j=1}^L \frac{1}{L+1} e_{v_j}^{(L+1)}. \quad (9)$$

3) 预测解释层. 预测解释层经过聚合操作得到用户的最终嵌入表示 e_{u_i} 和物品的最终嵌入表示 e_{v_j} , 最后使用内积来预测用户对物品的偏好分数:

$$\hat{y}_{u_i, v_j} = e_{u_i}^T e_{v_j}. \quad (10)$$

基于同质性理论,即个体具有与其他相似的人交往和发展的一种倾向,类似于“物以类聚,人以群分”,因此可以利用社交关系的推理帮助用户理解推荐结果. 而且从物品间语义联系的角度来看,推荐同类或互补的商品是很自然的,将其作为推荐结果的解释也符合用户的期望. SRGN 为用户推荐结果中的每个物品生成一个解释推理. 推理基于社交图和交互图中存在的各种实体及其关系信息,通过计算实体间关系的权重生成包括“用户的朋友喜欢该物品”和“与用户喜欢的物品相关的(相似、互补等关系)物品用户也会喜欢”两种意义的解释.

实体间关系的重要程度通过实体在关系图中传播经过的路径长度 L 来表示, L 越小表明实体之间关系越紧密. 关系路径太长会引入大量噪声信息,不利于捕捉实体之间的重要关系,因此

本文限制 $L \leq 3$. 社交关系图 G_u 中仅包含用户节点间的社交关系, 物品关系图 G_v 中仅包含物品节点间的语义联系, 利用多行为交互图 G_r 作为桥梁, 将 3 个图的信息进行融合得到包含所有信息的一个统一的图. 然后在其中探索用户 u 和算法计算得到的推荐结果之间的可能路径作为推荐结果的解释, 展示给用户来理解推荐系统的行为.

算法的损失函数包括两部分: 一部分是 BRP 损失^[12], 这是当前推荐系统中广泛使用的一种损失函数, 其核心思想是尽可能区分正样本与负样本的得分之差; 另一部分是 L_2 正则化损失, 其作用是避免参数更新过快从而产生过拟合:

$$L_2 = \sum_{(i,j) \in O} -\ln \sigma'(\hat{y}_{u,j^+} - \hat{y}_{u,j^-}) + \lambda \|\theta\|^2. \quad (11)$$

其中: O 为训练集中用户和物品间所有的交互关系; j^+, j^- 分别表示正样本对与负样本对间的交互关系; θ 是学习的超参数; $\sigma'(\cdot)$ 为 sigmoid 激活函数; λ 控制 L_2 正则化的调节强度防止过拟合.

时间复杂度分析. 模型嵌入层异构行为信息聚合过程时间复杂度为 $o((I+J \times K) \times d^2)$, 传播层信息传递时间复杂度为 $o(|E| \times d \times L)$, 其中 $|E|$ 表示关系总数, I, J, K 分别为用户、物品和异构行为的数量, d 表示嵌入维度, L 为传播层层数. 参数 I, J, K 取决于数据集的规模, 而参数 d 和 L 则取决于网络的结构复杂度. 当网络规模较大时, 对应的参数规模会变大, 模型复杂度将随之升高.

4 实验结果及分析

4.1 数据集及评价指标

实验使用两个公开的真实数据集. Epinions^[14] 数据集将用户的满意程度分为 5 个评分等级, 1 分为消极的, 5 分为积极的, 从而记录了不同用户对于社交网络评论系统的反馈结果. Yelp 使用分割线将数据集中的用户和物品的交互行为进行了良好的划分, 此外, 该数据集还囊括了用户的社交关系. 具体内容如表 1 所示.

表 1 数据集说明

Table 1 Description of datasets

社交关系	Epinions	Yelp
用户数量	18 081	43 043
物品数量	251 722	66 576
用户-物品交互数量	715 821	283 512
社会关系数量	590 641	549 451
物品关系数量	6 096 106	1 847 060

本文采用两种推荐系统广泛使用的评估指标命中率 (HR) 和归一化折损累计增益 (NDCG) 进行衡量. 其中 HR 为推荐结果中命中的概率, 用以表征模型的准确性. NDCG 用以衡量推荐结果和真实结果的差异, 从而表征模型的性能. 另外本文选取了 8 种经典或者当前最先进的推荐算法进行对比, 包括基于矩阵分解的经典推荐算法 (TrustMF^[17], SAMN^[7], EATNN^[8]) 和基于 GNN 的最新推荐算法 (GraphRec^[10], DANSER^[9], KCGN^[18], KGAT^[5], DGRec^[19]).

TrustMF, SAMN, EATNN 是基于矩阵分解的模型, 这些模型仅考虑用户单一行为的交互信息, 例如购买、点击等, 然后将这些信息与矩阵分解相融合, 用以学习用户和物品的嵌入表示. 而 GraphRec, DANSER, DGRec, KGAT 以及 KCGN 等基于 GNN 的模型重点将用户的交互信息和社交关系信息进行联合建模, 利用 GNN 高效的图学习能力捕获用户和物品的特征表示, 遗憾的是这些模型也仅仅考虑了用户的单一交互行为, 且均没有解释能力. 与上述框架相比, 同样基于 GNN 的 SRGN 模型不仅能够捕获用户的异构交互行为特征, 而且将物品间客观存在的语义联系也作为信息源, 与用户的交互信息和社交关系信息进行有效地联合建模, 从而包含更丰富且精准的语义信息, 而且 SRGN 还具备一定的解释能力.

4.2 参数设置及实验结果分析

本文将数据集随机划分为训练集、验证集和测试集, 从而在训练集上寻找最优参数, 并在验证集上评价模型, 最终利用测试集作为模型评估数据. 实验中, 设训练数据大小为 2 048, 用户和物品嵌入向量的维度为 64, 学习速率为 1×10^{-4} , 优化器选择 Adam. 两个数据集的图卷积层数都设为 1, 用以聚合一阶邻居信息. dropout 设定为 0.2, 防止过拟合. 为了验证算法的有效性, 本文从 3 个方面进行了实验验证.

4.2.1 SRGN 的总体性能

表 2 展示了本文算法 SRGN 和 8 个对比算法预测整体点击率的结果. 可以看出, SRGN 在所有推荐场景中始终获得最佳推荐性能, 这说明算法利用用户和物品的社交关系并使用 GNN 学习用户和物品的语义信息进行推荐是有效的.

与传统的社会化推荐方法相比, 基于图神经网络的方法通常会获得更好的性能, 这是因为后者对高阶特征的建模过程是非线性的, 从而能够

更加灵活准确地捕捉用户和物品的特征. 另外, 基于GNN的算法优于单纯基于注意力机制的社交推荐方法, 表明利用GNN进行迭代提取特征的效果强于单纯通过注意力网络提取特征的效果. 进一步与基于用户社交关系的算法相比, SRGN算法通过信息编码的方式不仅引入了用户的社交关系, 而且整合了物品间的语义联系, 从而获得更高的推荐性能. 同时以上模型基本只对单一交互行为建模研究, 而SRGN算法对不同的交互行为进行联合编码, 所以能够获得更为丰富的信息, 这有助于增强用户和物品的嵌入表示能力.

表 2 CTR 预测性能比较

Table 2 Performance comparison in CTR prediction

算法	Epinions		Yelp	
	HR	NDCG	HR	NDCG
TrustMF	0.6353	0.4179	0.7562	0.4959
SAMN	0.6390	0.4259	0.7514	0.4863
DGRec	0.6268	0.4127	0.7662	0.4954
EATNN	0.6422	0.4483	0.7715	0.5066
KGAT	0.6756	0.4708	0.7721	0.5113
GraphRec	0.6865	0.4786	0.7605	0.4943
DANSER	0.6693	0.4627	0.7740	0.5082
KCGN	0.7429	0.5131	0.8026	0.5308
SRGN	0.7573	0.5292	0.8213	0.5557

注: 表中加粗数据为最佳值, 下同.

此外为了评估不同的推荐列表长度对推荐性能的影响, 本文在Yelp数据集设置了不同的Top-K对比实验, 实验结果如表3所示. 可以看出SRGN算法的推荐性能优于所有对比算法, 这证明了本文的模型对于不同的推荐列表长度均具有稳定且良好的预测能力.

4.2.2 SRGN的可解释能力

得益于社交关系的嵌入, 算法可以利用高阶社交联系推断用户对物品的偏好, 并提供解释. 为此, 本文随机从Yelp数据集中选择一个用户 u_{10} , 用户推荐列表中得分最高的物品 i_{3774} 分数为84(满分100分). 本文根据 G_u , G_v 和 G_r 3个图中存在的关系来挖掘更丰富的高阶连接关系.

SRGN捕获基于用户社交关系和物品间语义联系的高阶路径. 这对于推断用户偏好有着关键性的作用, 收集到的路径信息可以作为推荐该物品的证据, 且用户的多行为(收藏、点击)也增加解释可信度, 用户 u_{10} 到推荐结果 i_{3774} 存在多条关

表 3 Yelp数据集不同Top-K下HR和NDCG预测排名
Table 3 Predicted ranking of HR and NDCG under different Top-K of Yelp dataset

算法	Top-K@5		Top-K@10		Top-K@15	
	HR	NDCG	HR	NDCG	HR	NDCG
TrustMF	0.6313	0.4625	0.7585	0.5128	0.8631	0.5334
SAMN	0.5997	0.4367	0.7518	0.4865	0.8273	0.507
DGRec	0.6117	0.4448	0.7665	0.4955	0.8398	0.5147
EATNN	0.6260	0.4555	0.7717	0.5069	0.8414	0.5254
KGAT	0.6397	0.4675	0.7722	0.5114	0.8542	0.5329
GraphRec	0.6234	0.4506	0.7608	0.4944	0.8342	0.5136
DANSER	0.6306	0.4627	0.7743	0.5085	0.8358	0.5247
KCGN	0.6595	0.4876	0.8026	0.5308	0.8681	0.5426
SRGN	0.6818	0.5104	0.8213	0.5557	0.8828	0.5698

系路径($L \leq 3$), 其中第一部分基于用户间的社交关系, 而其他则是基于物品间的语义联系, 算法生成如图2所示的推荐路径解释.




图 2 Yelp数据集用户的真实举例

Fig. 2 A real example of the user in Yelp dataset

由图2可知, 对于用户 u_{10} 而言, 物品 i_{3774} 得分最高是有据可循的, 首先用户 u_{10} 的多个朋友 u_{828} , u_{3120} 与物品 i_{3774} 直接或间接存在收藏、点击等交互行为, 因此基于同质性理论可知用户 u_{10} 对于物品 i_{3774} 的偏好分数更高. 另一方面, 物品 i_{3774} 与该用户曾经交互(购买、点击等)过的商品 i_{31200} 和 i_{37843} 存在语义上的间接关联. 综合两方面的证据可知将该物品推荐给用户 u_{10} 是有据可循且合情合理的.

社交关系的质量至关重要. 目前的用户社交关系信息比较单一, 统一表示为“朋友”, 这一主体社交关系, 而没有区分具体的关系类型, 因此, 在未来的工作中继续收集更为充分的关系信息, 进而实现更为详细的解释.

4.2.3 传播层数和嵌入维度的影响

传播层数和嵌入维度作为算法中最重要的两个超参数,图3和图4分别展示其值对推荐性能的影响.图3为用户和物品关系图上不同传播距离的实验结果.可以看出,聚合一阶邻居时模型达到最佳的预测效果,这表明对用户和物品间的客观联系进行建模有助于提升推荐性能,而忽略用户的社交关系和物品间的语义联系(传播距离为0)则不利于更精准的推荐.然而当聚合层数过高(传播距离大于1)时,模型的性能逐渐下降,这是由于传播距离大于1时包含的有效信息减少,而噪声信息增多.不难理解,对于特定用户而言,一阶邻居的关系强度远大于二阶、三阶邻居,因为二阶、三阶邻居相比一阶除了包含更少的该用户的特征信息外,还存有大量的其他用户信息,这些信息对于该用户的特征学习是无意义的,因此引入这些无用的信息(噪声),会极大影响该用户嵌入表示的学习效果,从而降低模型的准确性.图4展示了算法的预测精度随着嵌入维度的提升不断提高,这是因为算法的表示能力随着嵌入维度的增加而不断增强.然而,随着嵌入维度的进一步增加,性能不再提升甚至出现下降的趋势,这表明此时存在过拟合现象,从而算法的泛化能力降低.因此选择合适的嵌入维度至关重要.

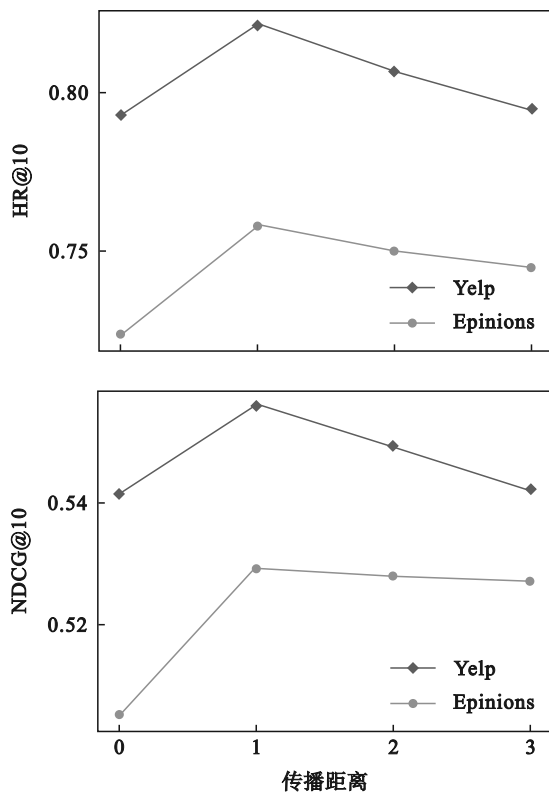


图3 传播距离比较

Fig. 3 Comparison of propagation layers

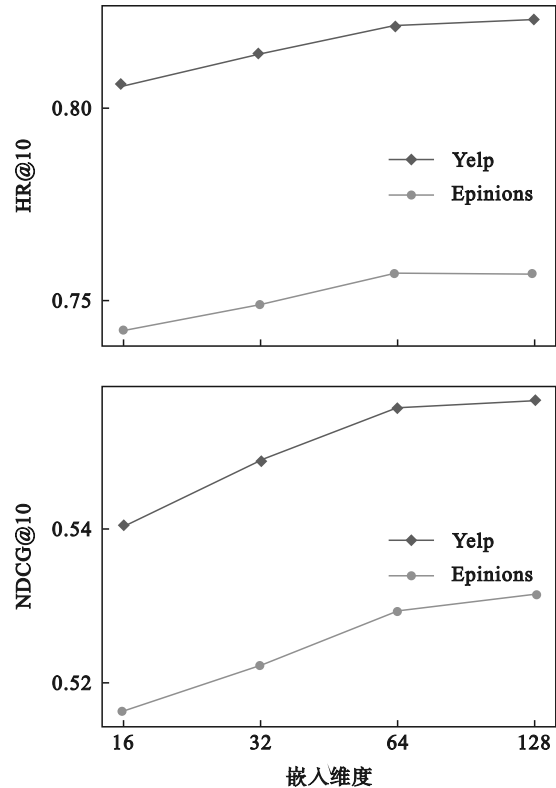


图4 嵌入维度比较

Fig. 4 Comparison of embedded dimension

5 结 语

本文提出了一种端到端的基于图神经网络的社交推荐算法 SRGN,不仅集成了用户的社交关系和物品语义联系,提出一种增强用户和物品语义信息表示的方法,同时还创造性地增加了社交推荐的可解释能力. SRGN将用户和物品的异构行为和社会关系信息嵌入与耦合图神经网络相结合,实现社会关系信息编码;算法充分利用社交关系信息和用户-物品交互信息以及物品之间的联系信息,探索用户和物品关系中的可能路径,从而为用户生成合理的 Post-hoc 推理解释.通过在两个真实数据集上的广泛实验,结果证明了 SRGN 算法与当前主流的个性化推荐算法相比具有更强的推荐性能.未来将深入研究图神经网络在相关领域的应用,比如,对于常规的 GNN 方法,在信息聚合过程中施加过平滑处理操作可以有效提升模型的学习效率,在用户社交图和用户物品交互图中是否有助于获得更多的社会关系信息以及获得社会关系信息是否有助于推荐性能的提升将作为未来研究的重点.此外考虑推荐算法解释能力的量化评价指标也是未来要进一步研究的内容.

参考文献:

- [1] Liu C H, Wang X, Lu T, et al. Discrete social recommendation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1):208-215.
- [2] Lyu Y X, Zheng Y, Wei F N, et al. AICF: attention-based item collaborative filtering [J]. *Advanced Engineering Informatics*, 2020, 44:101090.
- [3] 丁来旭, 刘洪娟. 复杂网络上基于多维特征表示学习的推荐算法[J]. *东北大学学报(自然科学版)*, 2022, 43(3):359-367.
(Ding Lai-xu, Liu Hong-juan. Recommendation algorithm based on multi-dimensional feature representation learning in complex networks[J]. *Journal of Northeastern University (Natural Science)*, 2022, 43(3):359-367.)
- [4] Guo G B, Zhang J, Yorke-Smith N. TrustSVD: collaborative filtering with both the explicit and implicit influence of user trust and of item ratings[J]. *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, 2015, 29(1):123-129.
- [5] Wang X, He X N, Cao Y X, et al. Kgat: knowledge graph attention network for recommendation [C]//*Proceedings of the KDD Conference on Machine Learning*. Anchorage: KDD, 2019:950-958.
- [6] 吴博, 梁循, 张树森, 等. 图神经网络前沿进展与应用[J]. *计算机学报*, 2022, 45(1):35-68.
(Wu Bo, Liang Xun, Zhang Shu-sen, et al. Advances and applications in graph neural network[J]. *Chinese Journal of Computers*, 2022, 45(1):35-68.)
- [7] Chen C, Zhang M, Liu Y Q, et al. Social attentional memory network: modeling aspect- and friend-level differences in recommendation [C]//*Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining*. Melbourne, 2019:177-185.
- [8] Chen C, Zhang M, Wang C Y, et al. An efficient adaptive transfer neural network for social-aware recommendation [C]//*Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Paris, 2019:225-234.
- [9] Wu Q T, Zhang H R, Gao X F, et al. Dual graph attention networks for deep latent representation of multifaceted social effects in recommender systems[C]//*The World Wide Web Conference*. San Francisco, 2019:2091-2102.
- [10] Fan W Q, Ma Y, Li Q, et al. Graph neural networks for social recommendation [C]//*The World Wide Web Conference*. San Francisco, 2019:417-426.
- [11] Ying R, He R N, Chen K F, et al. Graph convolutional neural networks for web-scale recommender systems [C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London, 2018:974-983.
- [12] Wang X, He X N, Wang M, et al. Neural graph collaborative filtering [C]// *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Paris, 2019:165-174.
- [13] He X N, Deng K, Wang X, 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*. New York, 2020:639-648.
- [14] Chen L, Wu L, Hong R C, et al. Revisiting graph based collaborative filtering: a linear residual graph convolutional network approach [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(1):27-34.
- [15] Peake G, Wang J. Explanation mining: post hoc interpretability of latent factor models for recommendation systems [C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London, 2018:2060-2069.
- [16] 朱海萍, 赵成成, 刘启东, 等. 基于互惠性约束的可解释就业推荐方法[J]. *计算机研究与发展*, 2021, 58(12):2660-2672.
(Zhu Hai-ping, Zhao Cheng-cheng, Liu Qi-dong, et al. Reciprocal-constrained interpretable job recommendation [J]. *Journal of Computer Research and Development*, 2021, 58(12):2660-2672.)
- [17] Yang B, Lei Y, Liu J M, et al. Social collaborative filtering by trust [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(8):1633-1647.
- [18] Huang C, Xu H C, Xu Y, et al. Knowledge-aware coupled graph neural network for social recommendation [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(5):4115-4122.
- [19] Song W P, Xiao Z P, Wang Y F, et al. Session-based social recommendation via dynamic graph attention networks [C]//*Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining*. Melbourne, 2019:555-563.