



计算机科学

COMPUTER SCIENCE

融合用户偏好的图神经网络推荐模型

熊中敏, 舒贵文, 郭怀宇

引用本文

熊中敏, 舒贵文, 郭怀宇. [融合用户偏好的图神经网络推荐模型](#)[J]. 计算机科学, 2022, 49(6): 165-171.

XIONG Zhong-min, SHU Gui-wen, GUO Huai-yu. [Graph Neural Network Recommendation Model Integrating User Preferences](#)[J]. Computer Science, 2022, 49(6): 165-171.

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)

[基于遗憾探索的竞争网络强化学习智能推荐方法研究](#)

Study on Intelligent Recommendation Method of Dueling Network Reinforcement Learning Based on Regret Exploration

计算机科学, 2022, 49(6): 149-157. <https://doi.org/10.11896/jsjcx.210600226>

[基于注意力机制和门控网络相结合的混合推荐系统](#)

Hybrid Recommender System Based on Attention Mechanisms and Gating Network

计算机科学, 2022, 49(6): 158-164. <https://doi.org/10.11896/jsjcx.210500013>

[基于注意力门控图神经网络的文本分类](#)

Text Classification Based on Attention Gated Graph Neural Network

计算机科学, 2022, 49(6): 326-334. <https://doi.org/10.11896/jsjcx.210400218>

[结合物品相似性的社交信任推荐算法](#)

Social Trust Recommendation Algorithm Combining Item Similarity

计算机科学, 2022, 49(5): 144-151. <https://doi.org/10.11896/jsjcx.210300217>

[基于用户覆盖及评分差异的多样性推荐算法](#)

Diversity Recommendation Algorithm Based on User Coverage and Rating Differences

计算机科学, 2022, 49(5): 159-164. <https://doi.org/10.11896/jsjcx.210300263>

融合用户偏好的图神经网络推荐模型

熊中敏 舒贵文 郭怀宇

上海海洋大学信息学院 上海 201306

(zmxiong@shou.edu.cn)

摘要 针对知识图谱驱动的图神经网络推荐算法无法同时学习用户和项目表示的问题,提出了融合用户偏好的图神经网络推荐模型,该模型分别从用户视角和实体视角学习用户和项目表示。首先,用户视角根据用户历史交互记录在知识图谱中传播用户偏好,增强用户表示;其次,实体视角通过图卷积网络聚集候选实体邻居信息以丰富实体的表示,同时设计一个混合层,分别从宽度和深度两个方面捕获高阶连通性和混合分层信息来增强项目表示,再将增强的用户表示向量和项目表示向量输入预测函数中,用于预测交互概率;最后,使用固定个数采样方法和阶段性训练策略优化模型的性能。在 MovieLens-1M 数据集上进行点击率预测实验,结果表明,所提模型的 AUC 与基准方法 RippleNet 和 KGCN 相比分别提升了 1.7% 和 2.3%。

关键词: 推荐系统;知识图谱;图神经网络;偏好传播;个性化推荐

中图法分类号 TP391.3;TP183

Graph Neural Network Recommendation Model Integrating User Preferences

XIONG Zhong-min, SHU Gui-wen and GUO Huai-yu

College of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract Aiming at the problem that knowledge graph-driven graph neural network recommendation algorithm cannot learn the user and item representations at the same time, a graph neural network recommendation model that integrates user preferences is proposed. The model learns user and item representations from user's perspective and entity's perspective respectively. Firstly, the user's perspective spreads user preferences in the knowledge graph based on user historical interaction records and enhances user representation. Secondly, the entity perspective gathers neighbor information of candidate entities through graph convolutional network to enrich the representation of the entity. At the same time, a hybrid layer is designed to capture high-level connectivity and hybrid hierarchical information from both the width and depth aspects to enhance the item representation. The enhanced user representation vector and item representation vector are input to the prediction function to predict the interaction probability. Finally, the fixed-size sampling method and phased training strategy are used to optimize the model. The click-through rate prediction experiment is conducted on the MovieLens-1M data set, and the results show that, compared with the benchmark methods RippleNet and KGCN, its AUC increases by 1.7% and 2.3% respectively.

Keywords Recommendation system, Knowledge graph, Graph neural network, Preference propagation, Personalized recommendation

1 引言

随着当前信息技术的迅猛发展,信息量呈现出几何爆炸式增长。巨大的信息量使得提升信息的获取效率显得尤为重要。推荐系统的产生正是为了解决信息爆炸所带来的问题,它会根据用户的历史交互记录,为用户推荐最感兴趣的内容。基于协同过滤^[1](Collaborative Filtering)的推荐算法依赖于用户和项目的历史交互,这导致了数据稀疏和冷启动的问题。为缓解这一问题,研究人员尝试为推荐加入一些辅助信息,如

社交网络^[2]、图片^[3]和评论^[4]等。

在众多辅助信息中,知识图谱(Knowledge Graph)被广泛使用,它是一种异构图,其中包含丰富的机器可识别的实体-关系-实体的三元组信息,对提升推荐结果的准确性、多样性和可解释性有着重要作用。基于知识图谱的推荐算法可以分为两类^[5]:基于路径的方法和基于嵌入的方法。

基于路径的方法^[6-8]侧重于实体之间的连接,并以这些路径为导向来学习用户与物品之间复杂而深层的关系。此方法虽然可以获得用户与物品交互的有效表示,但高度依赖于

到稿日期:2021-04-26 返修日期:2021-05-25

基金项目:国家自然科学基金(41501419);上海市地方院校能力建设项目(19050502100)

This work was supported by the National Natural Science Foundation of China(41501419) and Shanghai Local College Capacity Building Project(19050502100).

通信作者:舒贵文(422197957@qq.com)

所设计的路径来满足特定场景,且设计的路径通常需要大量的手工劳动和专业知识,这使得它们在不同的场景中缺乏可伸缩性。基于嵌入的方法^[3,9-10]通过知识图谱嵌入技术,如 TransE^[11], TransH^[12], TransR^[13] 和 TransD^[14] 等,将知识图谱的实体和关系嵌入到低维连续向量空间中,从而可以有效地存储知识图谱的固有结构,并在不同的关系下表示实体。但这种方法更适用于图内应用,如分类^[15]、链接预测^[11,16]、关系事实提取^[17]等,这些应用较少关注推荐任务中的用户-项目交互。此外,知识图谱嵌入通常需要提前训练,导致缺乏端到端的训练方式,并且它不能完全探索用户和项目之间的高阶连接。

随着对知识图谱研究的深入,学者提出了结合基于路径和基于嵌入的端到端的推荐框架,典型的有 RippleNet^[18] 和 KGCN^[19]。相比基于路径和基于嵌入的方法, RippleNet 不需要手工设计元路径,其通过用户历史交互记录在知识图谱中进行迭代传播,利用知识图谱的语义信息来建模用户偏好,有效提升了推荐的准确性和可解释性。KGCN 是一种基于图神经网络思想的推荐方法,通过聚合本地邻域结构中的邻域信息来探索用户对知识图谱的偏好,以此细化知识图谱中具有多跳邻居的项目表示,是使用知识图谱来驱动图神经网络进行推荐的最先进的模型。上述方法在思想上都有一定的先进性,但仍存在一定问题,具体如下:

- (1) 只侧重于单方面建模用户表示或者项目表示;
- (2) 实体之间关系的语义信息没有得到充分的挖掘,导致消息传递过程中的信息丢失;
- (3) 没有合适的采样策略对相关实体进行采样,导致计算和存储的成本较高。

针对以上问题,本文提出了融合用户偏好的图神经网络推荐模型(Graph Neural Network Recommendation Model Integrating User Preferences, GNNRM-UP),其分别从用户视角和实体视角学习用户和实体表示,弥补了现有模型不能同时学习用户和项目表示的缺陷。具体来说,从用户视角,将用户历史交互的实体集合作为种子集在知识图谱中传播,得到多跳的用户偏好集合,计算用户的交互历史记录中关于候选实体的多阶响应,再将结果输入到一个注意力网络中生成最终的用户表示;从实体视角,通过图卷积网络 GCN 聚集候选实体邻居信息以丰富实体的表示,同时,提出的层混合机制分别从宽度和深度两方面来捕获高阶连通性和混合分层信息,以增强项目表示;通过从用户和实体独特的混合视角来描述项目,固定个数采样方法和阶段性训练策略来优化模型。在真实电影数据集上进行相关实验,结果表明,与现有基准方法相比,所提方法在点击率预测(CTR)任务上的性能均有显著提升。

2 相关工作

2.1 用户偏好感知

利用知识图谱发掘用户偏好是知识图谱辅助推荐的一个主要的研究方向。如图 1 所示,用户曾看过电影《卧虎藏龙》和《一代宗师》,主演都是章子怡且都是动作片,而章子怡主演的动作片还有《十面埋伏》,因此,可以认为该用户对电影

《十面埋伏》有着潜在偏好。基于此思想,文献[20]提出了一种基于知识图谱和用户长短期偏好的个性化景点推荐方法,该方法利用门控循环单元建模序列化景点特征向量,并利用注意力机制来学习用户长短期偏好;文献[21]利用知识图谱整合多源异构数据,通过提取不同属性的基本特征,控制偏好在知识图谱中的传播强度,从而在偏好传播的同时兼顾不同属性的传播强度;文献[18]把用户偏好作为种子集在知识图谱中传播,自动发现点击历史到候选实体的可能路径,有效利用了知识图谱的结构信息。

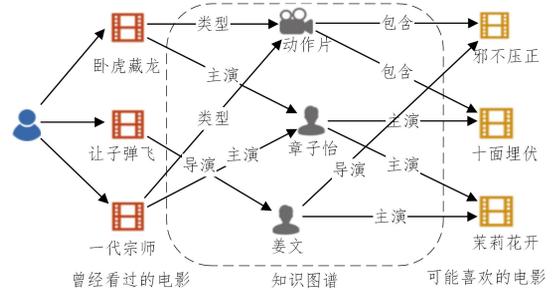


图 1 用户偏好感知

Fig. 1 User preference perception

2.2 基于图神经网络的推荐模型

文献[19]提出的 KGCN 是一个端到端的推荐框架,其通过挖掘项目在知识图谱上的相关属性来有效地捕获项目间的相关性。文献[22]提出将用户-项目交互矩阵与知识图谱相结合,以构建协同知识图,并在此图上使用图神经网络进行推荐。与文献[19]不同的是,该文提出结合图注意力网络的嵌入传播层,以此区分不同实体的重要性。基于知识图谱的图神经网络推荐方法在整合实体邻居信息方面对推荐性能的提升有着不可忽视的作用,但是上述方法都忽略了对用户表示的建模。

本文方法与上述图神经网络推荐方法的不同之处在于,本文充分考虑用户-实体交互和实体-实体交互,从这两个方面分别建模用户表示和实体表示,并以此作为推荐算法的最终输入。

3 相关概念和任务目标

在典型的推荐系统中,用户和项目集合被表示为 $U = \{u_1, u_2, \dots\}$ 和 $V = \{v_1, v_2, \dots\}$,用户-项目交互矩阵 $Y = \{y_{uv} \mid u \in U, v \in V\}$ 表征用户隐式反馈: $y_{uv} = 1$ 时,用户 u 和项目 v 存在交互, $y_{uv} = 0$ 时,用户 u 和项目 v 没有交互。文中将知识图谱以 G 表示,且 $G = \{(h, r, t) \mid h, t \in E, r \in R\}$,三元组 (h, r, t) 表示从头实体 h 到尾实体 t 的关系是 r , E 和 R 表示知识图谱中的实体集和关系集。候选项目 $v \in V$ 可能与知识图谱中的一个或多个实体相关联, $N(v)$ 表示 v 的邻居实体集合。

给定知识图谱 G 和用户交互矩阵 Y ,目标是预测用户 u 对没有交互的项目 v 是否有潜在的兴趣,即模型的最终目标是学习一个函数 $\hat{y}_{uv} = f(u, v; \vartheta, G)$, \hat{y}_{uv} 表示用户 u 点击项目 v 的概率, ϑ 表示模型的训练参数。此外,本文中所有知识图谱实体和关系嵌入参考了文献[18]的方法,实体和关系的嵌入分别表示为 $v \in R^d, R \in R^{d \times d}$, d 表示嵌入维度。

4 GNNRM-UP 整体框架

本文提出的 GNNRM-UP 主要由用户-实体交互和实体-实体交互两部分组成,模型框架如图 2 所示。用户-实体交互模块通过传播用户历史交互的偏好集合,使用知识图谱增强用

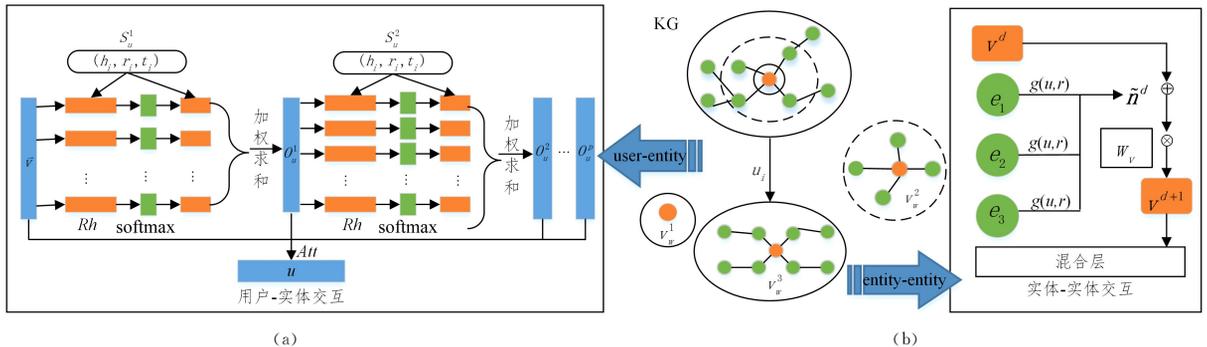


图 2 GNNRM-UP 的整体框架图

Fig. 2 Overall framework of GNNRM-UP

4.1 用户-实体交互

用户-实体交互模块根据包含用户点击信息^[16]的知识图谱实体来丰富用户表示。例如:用户观看了电影《卧虎藏龙》,《卧虎藏龙》的导演是李安,通过在知识图谱中进行拓展,发现李安也导演了电影《少年派的奇幻漂流》,因此可以认为该用户可能对电影《少年派的奇幻漂流》具有潜在兴趣。从用户视角来看,一个用户的兴趣不仅应由他所看过的电影来定义,还应由他可能感兴趣的知识图谱中的电影来定义。总之,以相关的知识图谱实体对用户表示进行建模,通过知识图谱增强的用户表示,使得面向用户的信息也得到增强,整个过程如图 2(a)和算法 1 所示。

算法 1 知识图谱增强用户表示(KGUR)

1. KGUR(u);
2. for $p=1, \dots, l_p$ do
3. $O_u^p \leftarrow \sum_{(h,r,t) \in S_u^p} p_i t_i$;
4. $\mathbf{u} = \sum_{k=1}^H w_k O_u^k$;
5. return \mathbf{u} .

使用知识图谱增强用户表示的详细过程如下:

(1) 偏好集合

首先,定义用户的偏好集合 S_u^p ,对于每一个用户 u ,以用户与之交互的项目集 $V_u = \{v | y_{uv} = 1\}$ 为知识图谱中的种子集,沿着关系探索构建偏好集合 S_u^p 。

$$E_u^p = \{t | (h, r, t) \in G \text{ 且 } h \in E_u^{p-1}\}, p=1, 2, \dots, l_p \quad (1)$$

当 $p=0$ 时, $E_u^0 = V_u$, E_u^p 记录从 $p-1$ 跳实体链接到 p 跳的实体。

$$S_u^p = \{(h, r, t) | (h, r, t) \in G \text{ 且 } h \in E_u^{p-1}\}, p=1, 2, \dots, l_p \quad (2)$$

其中, S_u^p 表示第 p 跳的偏好集合, E_u^p 仅表示尾实体, S_u^p 表示知识图谱中的三元组集合, p 表示偏好传播的跳数, l_p 表示最佳跳数。

(2) 偏好传播

知识图谱增强的用户表示由传播偏好集 S_u^p 生成的用户

户表示,从而得到用户多跳的偏好响应向量并将其输入到一个注意力网络,加权生成最终的用户表示;实体-实体交互模块通过图卷积网络 GCN 聚集候选实体邻居信息以丰富实体的表示,同时,设计了一个独特的混合层,分别从宽度和深度两方面捕获高阶连通性和混合分层信息,得到最终的项目表示。

偏好响应构成。对于给定用户 u 、候选实体 v 和一跳偏好集合 S_u^1 ,通过计算候选实体 v 与偏好集合 S_u^1 中每个三元组 (h_i, r_i, t_i) 的头实体 h_i 在关系空间 r_i 中的相关性,得到关于尾实体 t_i 的相关性概率 p_i :

$$p_i = \text{softmax}(\mathbf{v}^T R_i h_i) = \frac{\exp(\mathbf{v}^T R_i h_i)}{\sum_{(h,r,t) \in S_u^1} \exp(\mathbf{v}^T R h)} \quad (3)$$

其中, $\mathbf{v} \in R^d$, $\mathbf{R}_i \in R^{d \times d}$, $\mathbf{h}_i \in R^d$ 分别为实体 v , 关系 r_i , 实体 h_i 的向量表示, d 为向量表示的维度。为保证不同关系下,实体 v 与 h_i 具有不同的相似性,因此在计算相关性概率时必须考虑关系 R_i 。例如,在图 1 中,电影《卧虎藏龙》与《邪不压正》在电影类型这一关系中都属于动作片,而《让子弹飞》和《邪不压正》在导演这一关系中都指向导演实体姜文,因此根据用户历史交互的电影记录,可以认为该用户对电影《邪不压正》有着潜在偏好。在得到相关性概率后,使用此概率对尾实体进行加权求和,得到用户 u 的点击历史记录 V_u 对当前实体 v 的一阶响应 O_u^1 :

$$O_u^1 = \sum_{(h_i, r_i, t_i) \in S_u^1} p_i t_i \quad (4)$$

其中, $t_i \in R^d$ 为尾实体 t_i 的向量表示。根据多跳的偏好实体集合,即可得到用户 u 的点击历史记录对候选实体 v 的高阶响应 O_u^p 。显然,随着跳数的增加, O_u^p 所包含的有用信息逐渐减少。为准确把握不同跳数下不同 O_u^p 对最终用户表示的重要性,将不同跳数下的用户偏好响应向量 O_u^p 和候选实体 v 输入到一个注意力网络 Att 中,计算不同跳数 k 下用户偏好响应向量 O_u^k 的权重 w_k :

$$\begin{aligned} w_k &= \text{softmax}(Att(\mathbf{v}^T, O_u^k)) \\ &= \frac{\exp(Att(\mathbf{v}^T, O_u^k))}{\sum_{k=1}^p \exp(Att(\mathbf{v}^T, O_u^k))}, k=1, 2, \dots, l_p \end{aligned} \quad (5)$$

最后,以权重 w_k 加权用户偏好响应向量 O_u^k ,生成最终用户偏好向量表示 \mathbf{u} :

$$\mathbf{u} = \sum_{k=1}^{l_p} w_k O_u^k \quad (6)$$

4.2 实体-实体交互

在实体-实体交互中,以候选实体为起点,将图卷积网络

应用到知识图谱当中,聚集实体的邻居信息,生成包含邻居信息的实体向量,再将其输入到混合层,从深度和宽度两个方面捕获高阶连通性和混合分层信息,从而得到最终的向量表示。

4.2.1 单层 GCN 信息获取

当 GNNRM-UP 从知识图谱中给定项目的邻域收集信息时,我们以用户特定的方式对项目周围的每个关系进行评分,利用给定的用户和关系确定连接到候选项目的哪个邻居对用户更重要。例如,一些用户可能认为电影《霸王别姬》是因其主演是张国荣而出名,其他人可能认为电影《卧虎藏龙》是因其导演是李安而出名。因此,邻域中每个实体由相关分数 $\pi_{r_{v,e}}^u$ 加权,其中 u 表示不同的用户, $r_{v,e}$ 表示从实体 v 到相邻实体 e 的关系,最终,聚合加权的相邻实体嵌入,生成最终的面向用户的邻域信息 \mathbf{n} :

$$\mathbf{n} = \sum_{e \in N(v)} \tilde{\pi}_{r_{v,e}}^u e \quad (7)$$

$$\tilde{\pi}_{r_{v,e}}^u = \frac{\exp \pi_{r_{v,e}}^u}{\sum_{e' \in N(v)} \exp(\pi_{r_{v,e'}}^u)} \quad (8)$$

其中, $N(v)$ 表示实体 e 的一阶邻居, $\pi_{r_{v,e}}^u$ 表示面向用户的相关性关系分数,其计算式如下:

$$\pi_{r_{v,e}}^u = g(u, r) \quad (9)$$

函数 g 为向量内积运算,表示关系 r 对用户 u 的重要程度。在计算实体 e 的邻域表示时,由面向用户的相关性分数充当个性化过滤器,并由此聚集用户特定分数的偏差邻居。

4.2.2 层混合机制

基于面向用户的邻域信息,设计了一个混合层,用于捕获高阶连通性和混合分层信息。本文分别从深度和宽度两个方面对其进行了介绍,整个过程如图 3 和算法 2 所示。

算法 2 层混合机制 (MixLayer)

1. Mixlayer(\mathbf{v}, \mathbf{u});
2. $\tilde{\mathbf{e}}_1^{\mathbf{u}-1} \leftarrow \mathbf{v}$
3. for $w=1, \dots, l_w$ do
4. for $d=1, \dots, l_d$ do
5. for $e \in G$ do
6. $\tilde{\mathbf{n}}_w^d \leftarrow \sum_{e' \in N(e)} \tilde{\pi}_{r_{e',e}}^u \tilde{\mathbf{e}}_{e'}^d$;
7. $\tilde{\mathbf{e}}_w^{d+1} \leftarrow \text{agg}(\tilde{\mathbf{e}}_w^d, \tilde{\mathbf{n}}_w^d)$;
8. $\tilde{\mathbf{e}}_{w+1}^1 = M_w(\text{concat}([\tilde{\mathbf{e}}_w^1, \tilde{\mathbf{e}}_w^2, \dots, \tilde{\mathbf{e}}_w^{l_d}]))$;
9. return $\tilde{\mathbf{e}}_{l_w}^1$;

从深度来看,层混合机制整合了面向用户的邻域信息 $\tilde{\mathbf{n}}_w^d$,通过聚合函数 $\text{agg}(\cdot): \mathbb{R}^d \times \mathbb{R}^d \rightarrow \mathbb{R}^d$ 聚合得到下一阶的向量表示 $\tilde{\mathbf{v}}_w^{d+1}$;从宽度来看,该机制利用不同层次实体间的差异,允许其在不同顺序的实体之间进行比较,混合了不同距离的邻居特征的代表^[23],以进一步提升后续推荐的性能。具体来说,在每一层,使用层矩阵 M_w 混合当前层的图卷积网络信息 $(\tilde{\mathbf{v}}_w^1, \tilde{\mathbf{v}}_w^2, \dots, \tilde{\mathbf{v}}_w^d)$,并产生下一宽度实体表示 $\tilde{\mathbf{v}}_{w+1}^1$:

$$\tilde{\mathbf{v}}_{w+1}^1 = M_w(\text{concat}([\tilde{\mathbf{v}}_w^1, \tilde{\mathbf{v}}_w^2, \dots, \tilde{\mathbf{v}}_w^{l_d}])) \quad (10)$$

$$\tilde{\mathbf{v}}_w^{d+1} = \text{agg}(\tilde{\mathbf{v}}_w^d, \tilde{\mathbf{n}}_w^d) = \sigma(W_v(\tilde{\mathbf{v}}_w^d + \tilde{\mathbf{n}}_w^d) + b_v) \quad (11)$$

其中, $w=1, \dots, l_w-1; d=1, \dots, l_d-1; l_w$ 和 l_d 分别为宽度和深度; W_v 和 b_v 为训练参数。

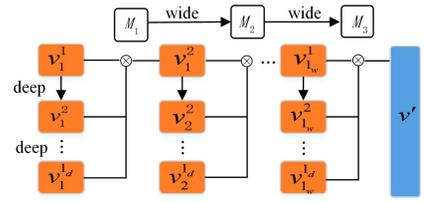


图 3 层混合机制

Fig. 3 Layer mixing mechanism

4.3 框架优化

GNNRM-UP 框架的完整步骤如算法 3 所示。对于给定的用户-项目对 (u, v) (算法 3 中第 2 行),首先生成用户表示 u (算法 3 中第 7 行)和项目表示 v' (算法 3 中第 8 行),用于计算用户 u 点击项目 v 的概率 \hat{y}_{uv} :

$$\hat{y}_{uv} = \sigma'(u^T v') \quad (12)$$

其中, σ' 为 sigmoid 函数。为优化 GNNRM-UP 的性能,使用负采样^[24]训练模型。损失函数的定义如下:

$$\mathcal{L} = \sum_{u \in U} \left(\sum_{v: y_{uv}=1} \mathcal{T}(y_{uv}, \hat{y}_{uv}) - \sum_{i=1}^{N^u} \mathbb{E}_{V_i \sim P(v_i)} \mathcal{T}(y_{u v_i}, \hat{y}_{u v_i}) \right) + \lambda \| \mathcal{F} \|_2^2 \quad (13)$$

其中,第一项 $\sum_{u \in U} \left(\sum_{v: y_{uv}=1} \mathcal{T}(y_{uv}, \hat{y}_{uv}) - \sum_{i=1}^{N^u} \mathbb{E}_{V_i \sim P(v_i)} \mathcal{T}(y_{u v_i}, \hat{y}_{u v_i}) \right)$ 中 \mathcal{T} 为交叉熵损失, P 为负采样的分布, N^u 为负采样的样本数, $N^u = |\{v: y_{uv}=1\}|$,且 P 遵循均匀分布;第二项 $\lambda \| \mathcal{F} \|_2^2$ 为 L_2 正则化损失。

4.3.1 固定个数采样

在现实世界的知识图谱中, $N(v)$ 值变化很大。此外, S_v^u 的值可能随着跳数的增加而变大。为了保证计算效率,采用固定个数采样策略^[19,25]对 4.1 节和 4.2.1 节中的实体进行采样。4.2.1 节中,为每个实体 v 统一采样固定个数的邻居集合 $N'(v)$,其中 $N'(v) \triangleq \{e | e \sim N(v)\}$, $N(v)$ 表示与 v 直接相连的实体, $|N'(v)| = K_n$ 为实体邻域采样个数。本文不为所有实体 $e \in G$ 计算下一阶实体表示,如算法 2 中第 5 行所示,仅抽样最少数量的实体计算最终实体嵌入向量 v' 。4.1 节中,在第 p 跳,对用户偏好集合 S_v^u 进行采样,以保证固定数量的相关实体, $|S_v^u| = K_m$, K_m 为偏好集合样本的个数。

4.3.2 阶段性训练

固定个数采样策略存在可能限制所有实体使用的潜在问题。如有限的样本空间可能忽视掉某些具有关键信息的实体,从而导致推荐性能不佳。为解决此类问题,本文引入了阶段性训练策略^[26-27]。具体来说,在每个阶段,阶段性训练都会对另一组实体进行重采样,以保证 GNNRM-UP 模型能从知识图谱中收集到更多信息。

算法 3 GNNRM-UP

输入:交互矩阵 \mathbf{Y} ,知识图谱 $G(E, R)$

输出:预测函数 $f(u, v | \Theta, \mathbf{Y}, G)$

1. Regular Training;
2. 初始化所有参数;
3. 为每个用户 u 计算偏好集合 S_u ;
4. 为每个候选实体采样邻居样本 N'_v ;
5. while GNNRM-UP has not converged do
6. for (u, v) in \mathbf{Y} do

7. $u \leftarrow \text{KGUR}(u)$;
8. $v' \leftarrow \text{Mixlayer}(u, v)$;
9. 计算预测概率 $\hat{y}_{uv} = f(u, v')$;
10. 通过梯度下降更新参数;
11. Stage-wise Training;
12. 初始化所有参数;
13. 保存实体和关系的嵌入;
14. while GNNRM-UP has not converged do
15. 初始化参数;
16. 加载上阶段实体和关系的嵌入;
17. 根据第3-4行重采样 S_n 和 N_v' ;
18. 重新计算第5-10行;
19. 保存最佳的实体和关系的嵌入;

5 实验讨论

5.1 数据集及实验设置

用于评估所提模型的数据集 MovieLens-1M 包含了由 2000 年加入 MovieLens 的 6040 个 MovieLens 用户制作的约 100 万条评分信息,评分范围为 1~5,实验使用的知识图谱来自文献[18]中已构建好的 MovieLens-1M 知识图谱。MovieLens-1M 为用户的显式反馈数据,设置阈值为 4,评分大于 4 的记录标记为 1,表示用户与该电影有过交互;评分小于等于 4 的记录标记为 0,表示用户与该电影没有交互。以此将显式反馈数据转化为隐式反馈数据。转化后的数据集信息如表 1 所列。

表 1 实验数据集

Table 1 Experimental dataset

数据类型	元素	统计值
用户-项目交互	用户	6040
	项目	2445
	评分	753772
知识图谱	实体	182011
	关系	12
	三元组	517057

本文的实验参数设置如下:将知识图谱向量表示的维度设置为 $d=16$,学习率 $\eta=0.02$,超参数 $\lambda_1=0.01, \lambda_2=10^{-7}$,设置实体邻域采样大小 $|N(v)'|=K_n=32$,跳数 $l_p=2$,偏好集合采样 $|S_n^p|=K_m=32$,深度 $l_d=2$,宽度 $l_w=1$ 。对于分阶段式训练,设置平均早期停止阶段数为 7。数据集中训练集、验证集、测试集各占 60%,20%,20%,模型评价指标为曲线下面积 (Area Under Curve, AUC) 和准确率 (Accuracy, ACC)。实验硬件环境为 NVIDIA GeForce GTX 965M 显卡,8GB 运行内存,Intel (R) Core (TM) i7-6700HQ 处理器,在 Tensorflow 框架下实现。

5.2 对比模型

与本文模型进行对比实验的基准方法的描述如下。

(1)CKE^[3]:基于正则化方法的模型,将协同过滤方法与结构化知识、文本和图像等信息融合在一个统一的框架中进行推荐。

(2)RippleNet^[18]:一种类似于记忆网络的方法,通过用户的相关项目来表示用户。RippleNet 使用知识图谱中的所有相关实体来传播用户偏好表示,从而进行推荐。

(3)KGCN^[19]:利用 GCN 从知识图谱中收集高阶邻域信息。为了找到用户可能更感兴趣的邻域,它使用用户相关实体的关系来计算邻域的权重。

(4)KGAT^[22]:一种使用图注意力网络的基于 GNN 的推荐模型,将知识图谱和用户-项目图的混合结构作为协作知识图,采用一种注意力机制区分邻居的重要性。

5.3 实验与分析

5.3.1 与基准方法的对比

GNNRM-UP 和基准方法的对比结果如表 2 所列。

表 2 点击率预测场景下各方法的 AUC 和 ACC 结果

Table 2 AUC and ACC of each method in click rate prediction

模型	scenarios			
	AUC	与 GNNRM-UP 的 AUC 的差值/%	ACC	与 GNNRM-UP 的 ACC 的差值/%
CKE	0.7960	-16.91	0.7390	-15.91
RippleNet	0.9155	-1.65	0.8396	-2.02
KGCN	0.9093	-2.34	0.8338	-2.73
KGAT	0.9203	-1.11	0.8489	-0.91
GNNRM-UP	0.9306	-	0.8566	-

由表 2 可知,CKE 在我们的实验中表现不佳,原因有两个方面:1)文本信息和视觉图像在我们的数据集中不可用;2)与其他模型相比,CKE 只使用一个与输入项直接相关的实体进行推荐。RippleNet,KGCN 和 KGAT 也取得了不错的性能,但仍没有超过 GNNRM-UP,这是因为 RippleNet 仅通过用户的点击历史来建模用户偏好,只学习了用户表示而没有合适的策略学习项目的聚合表示。类似地,KGAT 和 KGCN 通过图神经网络建模了项目的聚合表示,却忽略了用户偏好的建模,且 KGAT 没有混合 GCN 层的信息,这进一步导致一些有用的关键信息被忽视。与其他基线模型相比,GNNRM-UP 在 AUC 和 ACC 指标上均有所提升,这表明了 GNNRM-UP 的有效性。

5.3.2 模型不同组件对性能的影响

为验证本文模型的两个模块中的不同组件对模型性能的影响,我们做了相应的消融实验来探究各组件的有效性。在用户-实体交互模块中,用 KGUR 表示知识图谱增强的用户表示;在实体-实体交互模块中,GCIA 表示单层的 GCN 的信息聚合,ML 表示层混合机制,SW 表示阶段性训练。控制各个模块进行实验,结果如表 3 所列。

表 3 GNNRM-UP 消融研究的结果

Table 3 Results of GNNRM-UP ablation study

模型	组件				结果
	KGUR	GCIA	ML	SW	
GNNRM-UP	✓	✓	✓	✓	0.9306
GNNRM-UP _{KGUR}	-	✓	✓	✓	0.9121
GNNRM-UP _{ML}	✓	✓	-	✓	0.9130
GNNRM-UP _{SW}	✓	✓	✓	-	0.9122
GNNRM-UP _{DE}	✓	-	-	✓	0.9068

由表 3 可以看出,在分别移除 GNNRM-UP 中的某个组件时,模型的整体性能相比 GNNRM-UP 都有所下降,证明了 GNNRM-UP 中每个组件的有效性。对下降原因做如下解释:移除知识图谱增强的用户表示 (KG Enhance User Representation, KGUR) 时,最终用于预测的用户表示向量无法

聚集用户的偏好信息,这证实了同时学习用户表示和实体表示对于提升推荐性能的必要性;移除混合层(Mixed Layer, ML)后,在聚合邻居信息时实体的邻居信息仅能聚合有限的邻居信息,无法从深度和宽度挖掘信息;移除阶段性训练(Stage-wise Training, SW)后,模型性能也有所下降,说明阶段性训练通过重采样实体帮助 GNNRM-UP 收集了更多的实体信息,以更加完整地模拟整个邻居的全景。

综合 GNNRM-UP_{KGUR} 和 GNNRM-UP_{DE} 的阉割版模型的实验结果不难发现,单方面建模用户表示或实体表示,最终的结果相比完整版 GNNRM-UP 模型都有所不及,这充分说明了本文方法同时建模用户和实体表示对推荐性能的提升是有效的。

5.3.3 偏好集合和实体邻域大小的影响

为验证知识图谱增强用户表示中,偏好集合采样大小 K_m 和实体邻居集合采样大小 K_n 对模型性能的影响,本文进行了对比实验,实验结果如表 4 所列。

表 4 不同 K_m, K_n 对模型性能的影响

Table 4 Influence of different K_m and K_n on model performance

K_m size ($K_n=4$)	4	8	16	32	64
AUC	0.9133	0.9186	0.9242	0.9283	0.9253
K_n size ($K_m=16$)	4	8	16	32	64
AUC	0.9242	0.9250	0.9259	0.9268	0.9240

实验表明,用户偏好集合和实体邻域采样大小的选取对实验结果具有一定的影响。由表 4 可知,随着 K_m 和 K_n 的增大,模型的性能逐渐提升,且当 K_m 和 K_n 的采样大小为 32 时,模型性能最佳;随后继续扩大采样大小,模型的泛化能力开始呈下降趋势。其主要原因在于,采样集合不断扩大,采样获取到的信息也不断增多,在合适的采样大小范围内可大大提升模型的推荐性能;然而,当 K_m 和 K_n 的采样值过大时,采样集合中也会包含过多的噪声,不利于模型的优化。

5.3.4 偏好传播跳数和混合层深度、宽度对性能的影响

为探究偏好传播跳数 l_p 和层混合机制中宽度 l_w 、深度 l_d 对模型性能的影响,改变 l_p, l_w, l_d 的大小进行实验,当偏好传播的跳数 $l_p=0$ 时,表示用户偏好集合仅采用用户历史交互记录。实验结果如表 5 所列。

表 5 不同 l_p, l_w, l_d 对模型性能的影响

Table 5 Influence of different of l_p, l_w and l_d on model performance

l_p	0	1	2	3
AUC	0.9233	0.9296	0.9231	0.9196
l_w	0	1	2	3
AUC	—	0.9256	0.9269	0.9253
l_d	0	1	2	3
AUC	—	0.9255	0.9268	0.9252

由表 5 可知,当偏好传播的跳数 $l_p=1$ 时,模型性能最佳; l_p 值越大,不相关实体越多,噪声就越大,与文献[16]一致。对于混合层的宽度 l_w 和深度 l_d ,当值从 1 增加到 2 时,GN-NRM-UP 模型获得了更好的性能效果,表明增加跳数可以模拟高阶连通性。随着跳数继续增加,性能则开始下降,表明考虑的实体之间的二阶关系是足够的,这与文献[19,26]一致。

结束语 针对当前基于知识图谱的图神经网络推荐算法中没有合适的信息来传播算法学习用户的聚合表示和缺乏

可解释性等问题,本文提出了融合用户偏好的图神经网络推荐模型(GNNRM-UP),同时考虑用户-实体交互和实体-实体交互,融合知识图谱信息增强用户和实体表示,在公开数据集上进行实验,结果表明,所提方法较现有基准方法在各项指标上均有所提升,此外,通过消融实验证实了模型中每个组件的有效性。

今后,将进一步研究如何有效地将图注意力机制加入到项目表示学习中,为不同邻居节点赋予权重值,进而优化本文模型。

参考文献

- [1] 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. New York, USA: ACM, 2017: 173-182.
- [2] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]//Proceedings of the 4th ACM Conference on Recommender Systems. New York, USA: ACM, 2010: 135-142.
- [3] ZHANG F, YUAN N, LIAN D, et al. Collaborative knowledge base embedding for recommender systems[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA: ACM, 2016: 353-362.
- [4] SUN Y, YUAN N, XIE X, et al. Collaborative Intent Prediction with Real-Time Contextual Data [J]. ACM Transactions on Information Systems, 2017, 35(4): 30:1-30:33.
- [5] QIN C, ZHU H S, ZHUANG F Z, et al. Research review of recommendation system based on knowledge graph[J]. Science in China: Information Science, 2020, 50(7): 937-956.
- [6] YU X, REN X, GU Q, et al. Personalized entity recommendation: A heterogeneous information network approach[C]//Proceedings of the 7th ACM International Conference on Web Search and Data Mining. New York, USA: ACM, 2014: 283-292.
- [7] HUANG Z, ZHENG Y, CHENG R, et al. Meta structure: Computing relevance in large heterogeneous information networks [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, USA: ACM, 2016: 1595-1604.
- [8] HU B, SHI C, ZHAO W, et al. Leveraging meta-path based context for top-n recommendation with a neural co-attention model [C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 1531-1540.
- [9] HUANG J, ZHAO W, DOU H, et al. Improving sequential recommendation with knowledge-enhanced memory networks [C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York, USA, 2018: 505-514.
- [10] WANG H W, ZHANG F Z, XIE X, et al. DKN: Deep knowledge-aware network for news recommendation [C]//Proceedings of the 2018 World Wide Web Conference. Lyon, France, 2018: 1835-1844.

- [11] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data[J/OL]. Advances in Neural Information Processing Systems. <https://dblp.uni-trier.de/rec/conf/nips/BordesUGWY13.html>.
- [12] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[C]// Proceedings of the 28th AAAI Conference on Artificial Intelligence. Quebec, Canada, 2014:1112-1119.
- [13] LIN Y, LIN Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion[C]// Proceedings of the 29th AAAI Conference on Artificial Intelligence. Texas, USA, 2015:2181-2187.
- [14] JI G, HE S, XU L, et al. Knowledge graph embedding via dynamic mapping matrix[C]// Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing. Beijing, China, 2015:687-696.
- [15] SOCHER R, CHEN D, MANNING C D, et al. Reasoning with neural tensor networks for knowledge base completion [C]// Annual Conference on Neural Information Processing Systems. 2013:926-934.
- [16] GUAN N, SONG D, LIAO L. Knowledge graph embedding with concepts [J]. Knowledge-Based Systems, 2019, 164:38-44.
- [17] WESTON J, BORDES A, YAKHNENKO O, et al. Connecting language and knowledge bases with embedding models for relation extraction[C]// Conference on Empirical Methods in Natural Language Processing. Washington, USA, 2013:1366-1371.
- [18] WANG H W, ZHANG F Z, WANG J, et al. Ripplenet: Propagating user preferences on the knowledge graph for recommender systems[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management. Torino, Italy, 2018:417-426.
- [19] WANG H W, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems[C]// The World Wide Web Conference. San Francisco, USA, 2019:3307-3313.
- [20] JIA Z H, BIN C Z, GU T L, et al. Personalized attraction recommendation based on knowledge graph and long-term and short-term preferences of users[J]. Journal of Intelligent Systems, 2020, 15(5):990-997.
- [21] LIU Q, CHEN S P, HUO H. An entity recommendation model based on user preference dissemination of knowledge graph[J]. Application Research of Computers, 2020, 37(10):2926-2931.
- [22] WANG X, HE X N, CAO Y X, et al. KGAT: Knowledge Graph Attention Network for Recommendation [C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19). New York: ACM, 2019:950-958.
- [23] ABU-EI-HAJJA S, PEROZZI B, KAPOOR A, et al. MixHop: Higher-Order Graph Convolutional Architectures via Sparsified Neighborhood Mixing[J]. arXiv:1905.00067, 2019.
- [24] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed Representations of Words and Phrases and their Compositionality[J]. arXiv:1310.4546, 2013.
- [25] YING R, HE R, CHEN K, et al. Graph Convolutional Neural Networks for Web-Scale Recommender Systems[J]. arXiv:1806.01973, 2018.
- [26] TAICH Y, WU M R, CHU Y W, et al. GraphSW: a training protocol based on stage-wise training for GNN-based Recommender Model[J]. arXiv:1908.05611, 2019.
- [27] TAI C Y, WU M R, CHU Y W, et al. MVIN: Learning Multi-view Items for Recommendation [C]// 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, 2020:99-108.



XIONG Zhong-min, born in 1971, Ph.D. postdoctor, associate professor, is a member of China Computer Federation. His main research interests include database theory and application, data warehouse and data mining, network analysis technology and information recommendation.



SHU Gui-wen, born in 1997, postgraduate. His main research interests include knowledge graph and recommendation system.

(责任编辑:李亚辉)