

项目邻居信息对比增强的推荐方法

周北京¹,王海荣^{1,2*},马赫¹,张丽丝¹

(1.北方民族大学 计算科学与工程学院,宁夏 银川 750021;

2.北方民族大学 图像图形智能处理国家民委重点实验室,宁夏 银川 750021)

摘要:针对基于知识图谱推荐的方法中存在的用户-项目交互监督信号弱,以及知识图谱中包含噪声信息的问题。本文提出了一种项目邻居信息对比增强的推荐方法-RMCEIN(A Recommendation Method for Contrastive Enhancement of Item Neighbor Information)。RMCEIN通过异构传播和知识感知注意力函数获得用户和项目的多阶邻居嵌入,用于丰富用户和项目的特征;在项目邻居嵌入过程中采用添加均匀分布的弱噪声的方式,构建项目邻居增强视图,可以有效地减少视图构建的时间开销。此外,通过两个项目邻居视图间的对比学习,调用对比损失函数促使项目视图信息的均匀性,调节项目的邻居结构,达到减少知识图谱中知识噪声的目的,同时引入多任务学习来缓解监督信号弱的问题。为了验证方法的有效性,在三个公共数据集上进行实验,将实验结果与10种基于知识图谱的推荐方法进行了对比,本文方法的AUC(Area Under Curve)平均提升了2.32%,F1值平均提升了2.26%。

关键词:知识降噪;多任务学习;知识图谱;推荐方法

中图分类号:TP39

文献标志码:A

文章编号:0253-2395(2024)02-0269-10

Recommendation Method for Contrastive Enhancement of Item Neighborhood Information

ZHOU Beijing¹, WANG Hairong^{1,2*}, MA He¹, ZHANG Lisi¹

(1. College of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China;

2. The Key Laboratory of Images & Graphics Intelligent Processing of State Ethnic Affairs Commission, North Minzu University, Yinchuan, 750021, China)

Abstract: Aiming at the weak user-item interaction supervision signal in the knowledge graph-based recommendation method and the problem that the knowledge graph contains noise information, in this paper, we propose a recommendation method for contrastive enhancement of item neighbor information (RMCEIN). The RMCEIN obtains the multi-order neighbor embedding of users and items through heterogeneous propagation and knowledge-aware attention function, which is used to enrich the characteristics of users and items; in the process of item neighbor embedding, it adopts the method of adding uniformly distributed weak noise to construct item neighbor enhancement view, which can effectively reduce the time overhead of view construction. In addition, through contrastive learning between two item neighbor views, the contrastive loss function is called to promote the uniformity of item view information, adjust the neighbor structure of items, achieve the purpose of reducing knowledge noise in the knowledge graph, and at the same time introduce multi-task learning to alleviate the supervision signal weak problem. In order to verify the effectiveness of the method, experiments were carried out on the MovieLens-1M, Book-Crossing and Last-FM datasets, and the experimental results

收稿日期:2023-08-30;接受日期:2023-10-16

基金项目:宁夏自然科学基金(2023AAC03316);北方民族大学研究生创新项目(YCX23146;YCX23159)

作者简介:周北京(1997-),男,湖南衡阳人,硕士研究生,研究方向为知识图谱和推荐系统。E-mail:20217381@stu.nmu.edu.cn

*通信作者:王海荣(WANG Hairong),E-mail:bmdwhr@163.com

引文格式:周北京,王海荣,马赫,等.项目邻居信息对比增强的推荐方法[J].山西大学学报(自然科学版),2024,47(2):269-278. DOI:10.13451/j.sxu.ns.2023167

were compared with 10 methods such as RippleNet (Propagating User Preferences on the Knowledge Graph for Recommender Systems), CKAN, KGIC, etc. The AUC (Area Under Curve) of the method in this paper increased by 2.32% on average. F1 value increased by 2.26 on average.

Key words: knowledge distillation; multi-task learning; knowledge graph; recommended method

0 引言

个性化推荐算法能够从海量信息中挖掘出用户感兴趣的内容,以满足用户的个性化偏好。早期推荐效果较好的基于协同过滤(Collaborative Filtering, CF)的推荐方法,如NCF(Neural Collaborative Filtering)^[1]、ACF(Attentive Collaborative Filtering)^[2]等通过用户和项目交互的数据进行建模,以预测用户的偏好,但此类方法通常面临用户-项目交互数据稀疏,以及新用户冷启动的问题。为此,通过引入其他辅助信息,如用户或项目属性^[3]、社交网络^[4]和知识图谱^[5]等,用来辅助提升推荐效果的方法日益得到关注。知识图谱(Knowledge Graph, KG)作为推荐方法中一种有效的辅助信息,因其包含了大量具有语义关联的知识,通过建立实体与推荐中用户和项目的关联,以缓解数据稀疏和冷启动问题,在推荐方法中被广泛应用。当前,依据知识图谱在推荐方法中处理方式的不同,可分为基于嵌入的方法、基于路径的方法和基于传播的方法。其中,基于传播的方法,将KG的结构信息与语义关联信息相结合,普遍采用图卷积网络(Graph Convolution Network, GCN)挖掘知识图谱中的有效信息,用于丰富用户和项目的潜在表示。例如RippleNet(Propagating User Preferences on the Knowledge Graph for Recommender Systems)^[6]、AKUPM(Attention-enhanced Knowledge-aware User Preference Model)^[7]、CIEPA(Knowledge-enhanced recommendation using item embedding and path attention)^[8]等方法,通过KG中的链接(关系),传播用户的历史点击项目,进而探索用户的潜在兴趣,达到丰富用户表示和提高推荐性能的目的。KGCN(Knowledge Graph Convolutional Networks)^[9]和KGNN-LS(Knowledge-aware Graph Neural Networks with Label Smoothness regularization)^[10]在KG中采用GCN来细化项目表示。这些方法仅考虑增强用户或

项目的潜在特征,没有同时考虑用户和项目的表示增强。因此,Wang等^[11]提出了KGAT(Knowledge Graph Attention Network)模型,通过构建协同知识图谱,使用GCN和TransR来捕获KG中结构信息,以增强用户和项目表示。曹等^[12]采用对偶四元数来表示协同知识图谱,增强了捕获实体和关系之间复杂的潜在依赖。Wang等^[13]提出一种兼顾用户-项目的协同信息和知识图谱关联的CKAN模型,减少构建协同知识图谱引入用户节点噪声的问题,并突出协同信号在用户和项目表示的重要性。Xu等^[14]在CKAN基础上,引入注意力聚合器,区分不同邻居间的重要性,以丰富用户和项目嵌入的表示。此外,Qian等^[15]提出一种减少不相关知识的RKAC(Reduce unrelated Knowledge through Attribute Collaborative signal)模型,过滤项目属性中一些冗余知识。这些基于传播的方法可以有效地将聚合邻居信息到用户和项目的表示中,从而实现推荐性能的提升。但忽略KG本身包含大量嘈杂的知识,这些知识往往与推荐任务无关,若不加区分地聚合这些知识,会导致推荐性能不佳,如图1所示。




图1 电影推荐场景的示例

Fig. 1 Example of a movie recommendation scenario

在图1中,项目 i_1, i_2, i_3 与用户 u_1 交互,其中 i_1 与关系 r_1, r_2 相关联,而 i_2, i_3 与关系 r_2, r_3 相关联。可以推测用户 u_1 偏好电影的主演和类型,

而关系 r_1 对于用户 u_1 是一个噪声。在实际场景中, KG 往往存在大量的嘈杂冗余知识, 采用 GCN 进行邻居信息的聚合, 会导致 KG 中的噪声数据增大, 使得推荐性能不佳。此外, 当用户-项目交互数据稀疏时, 会导致监督信号弱的问题, 从而影响推荐效果。

针对 KG 存在知识噪声和监督信息弱的问题, 本文提出了一种项目邻居信息对比增强的推荐方法 RMCEIN (A Recommendation Method for Contrastive Enhancement of Item Neighborhood Information)。该方法通过异构传播结合知识图谱和用户-项目交互信息, 以显式编码用户-项目的协同信号; 采用知识感知注意力函数捕获邻居信息中重要的知识, 减少知识噪声; 利用项目邻居增强来进一步减少项目邻居中所包含的知识噪声, 并通过多任务策略结合推荐任务和对比学习以增强监督信号。

1 RMCEIN方法模型

RMCEIN 采用异构传播, 将用户-项目交互的协同信息与 KG 中的邻居信息结合, 通过知识感知注意力函数和对比学习来减少 KG 中的噪声以及增强监督信号, 方法模型如图 2 所示。

RMCEIN 由异构传播、知识感知注意力函数、项目邻居的对比学习和预测与学习 4 个核心模块组成。异构传播是结合用户-项目图及知识图谱, 实现用户-项目交互信息和知识图

谱的连通, 以获取用户和项目在 KG 中传播生成的不同层的邻居信息集 $\{S_u^1, S_u^2, \dots, S_u^L\}$ 和 $\{S_v^1, S_v^2, \dots, S_v^L\}$ 。由于不同层的邻居信息对用户和项目的重要性存在差异, 本文采用知识感知注意力函数来计算每层邻居中知识(三元组)的权重, 实现细粒度的邻居信息编码, 用户和项目的邻居嵌入集为 $\{e_{S_u^1}, e_{S_u^2}, \dots, e_{S_u^L}\}$ 和 $\{e_{S_v^1}, e_{S_v^2}, \dots, e_{S_v^L}\}$ 。为避免聚合操作导致项目的邻居嵌入包含大量噪声的问题, 本文引入了项目邻居的对比学习模块, 对项目的邻居嵌入集 $\{e_{S_v^1}, e_{S_v^2}, \dots, e_{S_v^L}\}$ 进行有目的引入服从均匀分布的噪声, 来生成一个增强的项目邻居嵌入集 $\{e'_{S_v^1}, e'_{S_v^2}, \dots, e'_{S_v^L}\}$, 同时采用对比学习来学习视图间的共同特征, 以减少项目邻居嵌入中的噪声数量。在预测与学习模块, 聚合各邻居嵌入得到用户和项目的最终表示 e_u 和 e_v^* , 并结合推荐任务和自监督学习任务进行用户对项目偏好的预测。

2 异构传播

在图 2(a)中, 异构传播由协同传播和知识传播两个部分组成。其中, 协同传播根据用户-项目交互构建用户和项目的初始实体集, 而知识传播以两个初始实体集为基础, 探索用户和项目在知识图谱的邻居集。

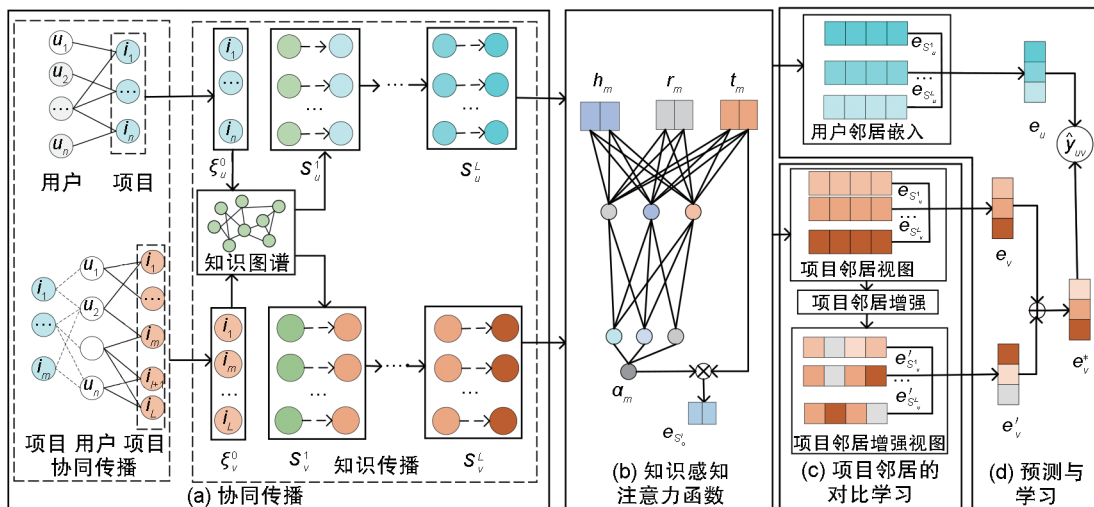


图 2 RMCEIN 的整体架构

Fig. 2 The overall architecture of RMCEIN

2.1 协同传播

协同传播是从用户-项目交互数据中获取关键的协同信号,并显式编码为用户和项目的表示。根据用户-项目的交互数据能反映用户的部分偏好,用户的表示可以通过相关项目体现。即用户 u 的初始实体集 ξ_u^0 定义如式(1):

$$\xi_u^0 = \{e|(v, e) \in A, v \in \{v|y_{uv} = 1\}\}, \quad (1)$$

其中, A 为项目-实体对齐集合, $y_{uv} = 1$ 表示用户与项目交互的数据。

考虑到一个项目可以被多个用户交互的场景,本文采用“项目-用户-项目”传播策略,将用户-项目交互信息包含在项目的初始实体集中,以丰富项目的表示。“项目-用户-项目”的传播过程如图3所示。




图3 项目-用户-项目传播过程

Fig. 3 Item-user-item propagation process

在图3中,项目 i_1 与用户 u_1 和用户 u_2 存在交互,而用户 u_1 参与项目 i_1 和项目 i_2 的交互,因此,项目 i_2 协同传播集为 $\{i_1, i_2, i_4\}$,即项目通过用户为桥梁,构建项目-项目潜在关系以获取项目的初始实体集。设项目 v 的初始实体集为 ξ_v^0 ,其定义如下:

$$\xi_v^0 = \{e|(v, e) \in A, v \in \{v|y_{uv} = 1\}\}, \quad (2)$$

其中, $y_{uv} = 1$ 表示相同用户的不同项目之间的关联,将用户-项目的协同信号显式地包含在项目-项目视图中。将协同传播获得的用户和项目的初始实体集 (ξ_u^0 和 ξ_v^0) 作为知识传播的种子集。

2.2 知识传播

知识传播是从KG获得用户和项目的多阶邻居集,模拟用户和项目在KG传播的潜在兴趣。具体来说,以用户和项目初始实体集 (ξ_u^0 和 ξ_v^0) 为种子,沿着KG的关系传播,以获得关联的实体,构建用户 u 和项目 v 的多跳实体集。对于第 l 阶的用户和项目在KG传播生成实体集 ξ_o^l 定义如下:

$$\xi_o^l = \{t|(h, r, t) \in G, h \in \xi_o^{l-1}\}, l = 1, 2, \dots, L, \quad (3)$$

其中, o 为用户 u 或者项目 v 的统一占位符。 G 代表知识图谱, (h, r, t) 为知识图谱中的三元组。 ξ_o^l 表达以 ξ_o^{l-1} 为头实体寻找KG关联的尾实体 t 作为第 l 阶的头实体。

为了获取KG中的结构信息和语义信息,以知识传播生成的关联实体 ξ_o^l 作为头实体集,获取各三元组作为用户和项目的邻居集。对于第 l 阶用户或项目的邻居集 S_o^l ,定义头实体集为 ξ_o^l ,查找KG中三元组中对应的关系和尾实体,以形成用户和项目邻居集。其第 l 阶邻居集 S_o^l 定义如下:

$$S_o^l = \{(h, r, t) | (h, r, t) \in G, h \in \xi_o^{l-1}\}, \quad l = 1, 2, \dots, L, \quad (4)$$

其中, S_o^l 以实体集 ξ_o^{l-1} 为头实体构成的三元组集。

知识传播建立了用户-项目交互数据与知识图谱的关联,而各邻居集 $\{S_o^1, S_o^2, \dots, S_o^L\}$ 为挖掘KG中结构信息和语义信息,增强用户和项目的特征表示提供了材料。

3 知识感知注意力函数

为了探索邻居集 $\{S_o^1, S_o^2, \dots, S_o^L\}$ 对用户和项目表示的重要性,充分考虑用户和项目在不同关系链接下的尾实体的偏好不同。本文提出一种知识感知注意力函数,计算邻居中每个三元组注意力权重来揭示不同的三元组表达含义的差异性,以有效编码邻居中各知识(三元组),如图2(b)所示。

考虑 S_o^l 中第 m 个三元组 (h_m, r_m, t_m) 知识感知注意力嵌入 β_m ,如下式:

$$\beta_m = \alpha_m t_m, \quad (5)$$

其中, α_m 为知识感知注意力函数,用于学习邻

居中各三元组的重要性。 α_m 定义如下式:

$$\alpha_m = \sigma(W_2 \text{Leakrelu}(W_1 Z + b_1) + b_2), \quad (6)$$

$$Z = \text{Leakrelu}(W_0(h_m \| r_m \| t_m) + b_0), \quad (7)$$

其中, Leakrelu 为非线性激活函数,防止梯度消失。 σ 为激活函数 sigmoid, $\|$ 是拼接操作。

此外,采用 softmax 函数对三元组的系数 α_m 进行归一化,如下式:

$$\tilde{\alpha}_m = \frac{\exp(\alpha_m)}{\sum_{(h_m)} \exp(\alpha_m)}. \quad (8)$$

最后,邻居 S'_o 的嵌入可以表示如下式:

$$e_{S'_o} = \sum_{m=1}^{S'_o} \beta_m \quad (9)$$

其中, $e_{S'_o}$ 表示邻居 S'_o 嵌入。

邻居集 $\{S'_o, S'_o, \dots, S'_o\}$ 经过知识感知注意力计算获取各邻居的嵌入可表示为 $\{e_{S'_o}, e_{S'_o}, \dots, e_{S'_o}\}$ 。由于知识感知注意力仅从细粒度的知识(三元组)来减少知识噪声,而忽略邻居结构中包含知识噪声。因此,需要额外地引入对比学习来调节邻居结构不平衡问题,以增强邻居嵌入。

4 项目邻居的对比学习

对比学习是一个自监督学习任务,不依赖监督学习的标签数据,而是关注数据本身的特征。根据在自然语言处理(Natural Language Processing, NLP)和计算机视觉(Computer Vision, CV)领域应用对比学习发现的两个关键因素:特征对齐和特征均匀性约束。本文根据知识感知注意力函数编码的项目邻居嵌入集作为项目邻居视图,采用符合特征均匀性项目邻居增强来进行数据扩充,生成项目邻居增强视图,如图2(c)所示。在项目邻居视图之间运用对比损失函数来调节邻居结构,以降低项目邻居中的噪声。

4.1 项目邻居增强

在项目邻居的嵌入集 $\{e'_{S'_o}, e'_{S'_o}, \dots, e'_{S'_o}\}$ 中引入服从均匀分布的噪声,模拟特征的均匀性。对于项目邻居嵌入 e_s , 其项目邻居增强的嵌入 e'_s , 如下式:

$$e'_s = e_s + \Delta_s, \quad (10)$$

其中, Δ_s 为添加的噪声向量,且 $\|\Delta_s\| = \epsilon$ 是一个小常数($\epsilon < 0.3$)。为了限制 Δ_s 在数值上等同半

径为 ϵ 的超球面上的点,如下式:

$$\Delta_s = I \odot \text{sign}(e_s,) I \in R^d \sim U(0, 1). \quad (11)$$

通过噪声 Δ_s 构建的 e'_s 保留了大部分原始特征且带来了一些差异。

相比在项目邻居的嵌入中采用 dropout 技术损失丢失部分特征,本文的项目邻居增强引入的噪声服从特征均匀性,并没有丢失特征。此外,本文构建的项目邻居增强视图比通过结构扰动构建的视图,无额外的视图构建的时间开销。

4.2 对比损失函数

为了最大化项目邻居视图间的互信息,采用 InfoNCE^[16] 作为对比损失函数,以减少项目邻居中知识噪声,增强项目的表示。具体来说,对于每个项目 i , 经过 L 阶迭代传播,项目邻居嵌入为 $\{e_{S'_o}, e_{S'_o}, \dots, e_{S'_o}\}$, 采用项目邻居增强的表示为 $\{e'_{S'_o}, e'_{S'_o}, \dots, e'_{S'_o}\}$ 。将相同阶的项目邻居嵌入视为正对(即 $e_{S'_o}$ 和 $e'_{S'_o}$), 反之视为负对。对比损失函数 InfoNCE 表示如下:

$$L_{\text{InfoNCE}} = -\sum_{l \in L} \log \frac{\exp(e_{S'_o} \cdot e'_{S'_o} / \tau)}{\sum_{k' \in l} \exp(e_{S'_o} \cdot e'_{S'_o} / \tau)}, \quad (12)$$

其中, τ 是温度参数,调控样本的均匀分布。通过 InfoNCE 引入额外的监督信息,能够鼓励项目邻居嵌入均匀分布在潜在空间中,以便预测时更好区分其差异性

5 预测与学习

为了探究用户的个性化偏好,本文采用内积来计算用户对项目的分数,如图2(d)所示。并使用多任务学习策略来联合推荐任务和自监督学习任务,完成模型优化。

5.1 模型预测

经过知识感知注意力编码的邻居嵌入集为 $\{e_{S'_o}, e_{S'_o}, \dots, e_{S'_o}\}$, 而用户和项目用户和项目的初始实体集(ξ_u^0 和 ξ_v^0) 包含协同信息,其协同嵌入表示为 $e_{S'_o}$ 和 $e_{S'_o}$ 。为了最大化保留全部信息,通过拼接各邻居嵌入和协同嵌入以获得用户和项目的最终嵌入,如下式:

$$e_o = e_{S'_o} \| e_{S'_o} \| e_{S'_o} \dots \| e_{S'_o}, \quad (13)$$

其中, o 为统一占位符,表示用户 u 和项目 v 的特征。此外,考虑到项目邻居增强是添加弱噪

声来增强项目的邻居嵌入,将增强项目的邻居嵌入集 $\{e'_{s_1}, e'_{s_2}, \dots, e'_{s_t}\}$ 直接用于推荐任务。最终的项目表示 e_v^* , 如下式:

$$e_v^* = e'_v + e_v, \quad (14)$$

$$e'_v = e'_{s_1} \parallel e'_{s_2} \parallel \dots \parallel e'_{s_t}. \quad (15)$$

根据最终的用户表示 e_u 和项目表示 e_v^* , 用户偏好函数 $\hat{y}(u, v)$ 为:

$$\hat{y}(u, v) = e_u^T e_v^*. \quad (16)$$

5.2 多任务学习

为了将推荐任务和自监督学习结合,采用多任务训练策略优化整个模型。对于知识感知的推荐任务,采用BPR损失函数,如下式:

$$L_{\text{BPR}} = \sum_{(u,i,j) \in O} -\ln \sigma(\hat{y}_{ui} - y_{uj}), \quad (17)$$

其中, $O = \{(u, i, j) | (u, i) \in o^+, (u, j) \in o^-\}$ 是可训练的数据集,用户-项目有交互记为 o^+ , 用户-项目无交互记为 o^- , 并设置 o^+ 与 o^- 数据比例为 1:1, σ 为是 sigmoid 函数。

采用多任务学习将监督信号和自监督信号结合,共同训练模型,本模型最终的损失函数如下式:

$$L = L_{\text{BPR}} + \lambda_1 L_{\text{InfoNCE}} + \lambda_2 \|\Theta\|_2^2 \quad (18)$$

其中, Θ 为模型参数集, $\|\Theta\|_2^2$ 是以 λ_2 为参数的 L2 范式。

6 实验对比与分析

为了评估本方法的有效性,在 MovieLens-1M、Book-Crossing 和 Last.FM 三个数据集上进行实验,具体如表 1 所示。

表 1 数据集的统计

Table 1 Statistics of the datasets

参数	MoieLens-1M	Book-Crossing	Last.FM
用户	6 036	17 860	1 872
项目	2 445	14 967	3 846
交互	753 772	139 746	42 346
稀疏度	5.11%	0.05%	0.59%
实体	182 011	77 903	9 366
关系	12	25	60
三元组	1 241 996	151 500	15 518

每个数据集按 6:2:2 划分为训练集、验证集和测试集,采用 Adam 优化器进行模型优化,批次大小设置为 2 048,使用 Xavier 初始化模型

参数,其他重要超参数的设置如表 2 所示。

表 2 各数据集中的参数设置

Table 2 Parameter settings in datasets

参数	MoieLens-1M	Book-Crossing	Last.FM
维度(D)	64	64	64
层数(H)	3	2	2
用户的邻居数	128	128	128
项目的邻居数	16	64	64
调控参数 λ_1	10^{-7}	10^{-6}	10^{-6}
学习率 λ_2	0.002	0.002	0.005
温度参数(τ)	0.15	0.15	0.15
噪声参数(ϵ)	0.5	0.1	0.1

6.1 方法性能评估

本文采用 AUC 和 F1 作为点击率(CTR)的性能评价指标,与 RippleNet、KGCN、CKAN 等 10 种主流方法模型进行实验结果的对比分析,多次实验结果的平均值如表 3 所示。

表 3 不同的推荐模型的性能对比

Table 3 Performance comparisons among different recommendation models

方法	MovieLens-1M		Book-Crossing		Last.FM	
	AUC	F1	AUC	F1	AUC	F1
RippleNet ^[6]	0.843 2	0.756 3	0.726 3	0.647 2	0.793 8	0.702 5
KGCN ^[9]	0.900 1	0.826 1	0.692 2	0.633 6	0.803 1	0.710 7
KGNN-LS ^[10]	0.914 0	0.841 0	0.689 0	0.633 4	0.804 2	0.728 3
KGAT ^[11]	0.910 2	0.840 4	0.719 4	0.654 4	0.805 4	0.722 4
CKAN ^[13]	0.917 0	0.849 4	0.745 3	0.666 7	0.846 3	0.771 5
COAT ^[16]	0.912 2	0.836 7	0.740 7	0.661 1	0.821 5	0.749 9
LKGR ^[17]	0.917 8	0.841 9	0.679 3	0.629 6	0.796 3	0.721 9
KGIN ^[18]	0.919 0	0.844 1	0.727 3	0.661 4	0.846 3	0.760 2
CG-KGR ^[19]	0.911 0	0.835 9	0.749 8	0.668 9	0.833 6	0.743 3
KGIC ^[20]	0.925 2	0.851 0	0.765 2	0.675 4	0.846 6	0.775 3
RMCEIN(our)	0.928 5	0.861 0	0.774 3	0.688 5	0.859 5	0.780 2

同表 3 中其他基于知识图谱的推荐方法相比,本方法在三个数据集上的 AUC 和 F1 均获得较好性能,验证了本方法的有效性。具体而言,本方法在 Book-Crossing 和 Last.FM 数据集中比 MovieLens-1M 数据集提升明显,这是因为 Book-Crossing 和 Last.FM 比 MovieLens-1M 更加稀疏,说明知识图谱的引入为稀疏数据集中的用户和项目的潜在表示提供丰富特征。

RippleNet 仅考虑用户在 KG 中的传播偏好,缺少项目的丰富。类似的, KGCN 和 KGCN-LS 聚合邻居信息来丰富项目嵌入,但忽

略用户的表示。本方法考虑采用异构传播来获取KG中用户和项目的邻居,实现同时丰富用户和项目的表示。KGAT、CKAN、COAT、KGIN、CG-KGR等都考虑通过KG来丰富用户和项目的嵌入,但侧重传播和聚合策略的设计,未考虑知识图谱存在大量噪声数据。本方法采用对比学习来减少KG中的噪声。相比KGIC构建多层次交互视图进行对比学习,时间复杂度高。本方法仅添加弱噪声构建项目邻居增强的嵌入视图,减少了项目邻居视图构建的时间复杂度。

CTR预测旨在估计用户点击项目的概率,而Top-K推荐需要为用户对项目空间中所有项目进行排序。为了进一步验证本方法在Top-K上的有效性,使用Recall@K进行前K个推荐结果评估,设 $K=[5, 10, 20, 50, 100]$ 。所有实验均进行5次并取平均结果作为记录,如图4所示。

由图4可知,本模型在三个数据集上整体性能最好。与Last-FM、Book-Crossing和MovieLens-1M上最佳模型相比,本方法提升明显。在图4(a)和图4(c)中,recall@K值提升明显,说明引入对比学习能够区分项目邻居中难区分的样本,减少知识噪声。在图4(b)中,本方法与CKAN接近,可能是MovieLens-1M中对应的知识图谱包含的噪声少,导致对比学习引入不能明显改善其推荐性能。

6.2 消融实验

为了研究异构传播、知识感知注意力机制和对比学习对推荐性能的影响,本文进行消融实验。分别设置:(1)去掉对比学习模块,记作 $RMCEIN_{w/o\ CL}$; (2)禁用知识感知注意力机制,采用 $1/|S'_o|$ 替换公式(6)中的 α_m ,记为 $RMCEIN_{w/o\ att}$; (3)消去项目邻居数据增强方法,采用dropout技术进行项目邻居增强,记为 $RMCEIN_{w/o\ nei}$; (4)去掉异构传播中的协同传播,直接采用项目本身作为初始实体集,记为 $RMCEIN_{w/o\ IG}$ 。消融实验结果如表4。

由表4可知,在三个数据集中删去对比学习模块($RMCEIN_{w/o\ CL}$)会导致模型的性能下降,说明对比学习在本方法中起了重要作用,引入对比学习能自适应地调节项目邻居的结

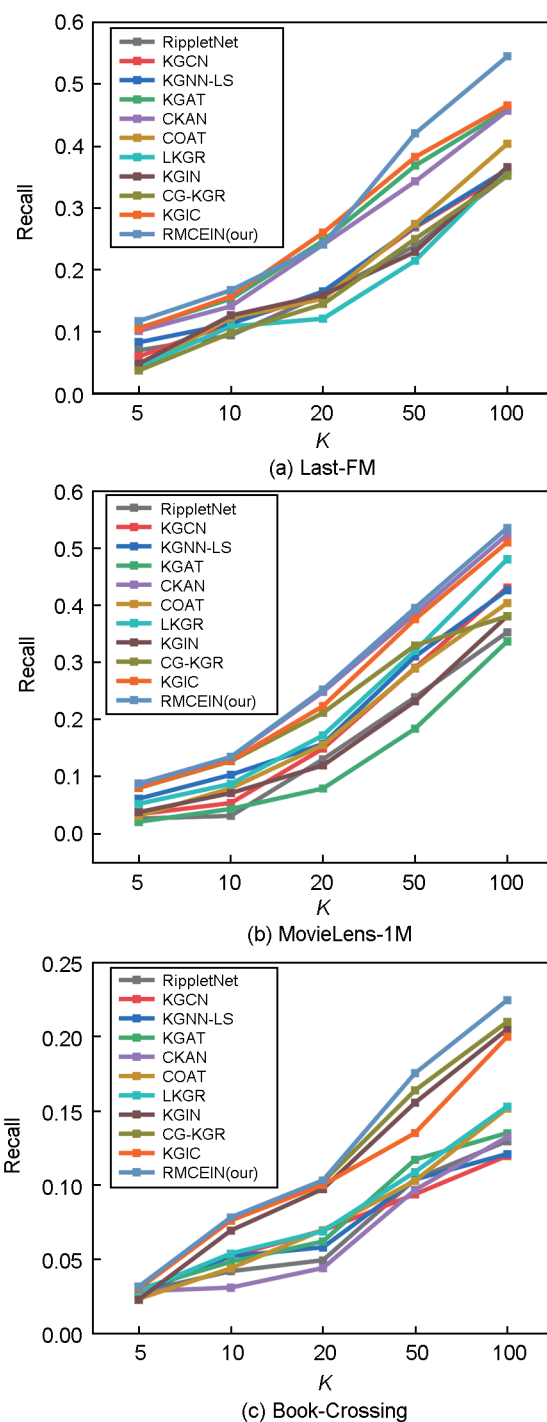


图4 三个数据集上的Recall@K

Fig. 4 Recall@K in three datasets

构,减少项目邻居中的噪声知识而提高推荐性能;在三个数据集中禁用知识感知注意力机制($RMCEIN_{w/o\ att}$)将导致模型的性能显著下降,说明本文的知识感知注意力能够有效捕获各邻居中重要的知识,降低无关三元组的干扰;在三个数据集中消去项目邻居数据增强模块($RMCEIN_{w/o\ nei}$),采用dropout技术生成项目邻居嵌

表4 消融实验结果

Table 4 Results of ablation experiment

模型	MovieLens-1M		Book-Crossing		Last.FM	
	AUC	F1	AUC	F1	AUC	F1
RMCEIN _{w/o} CL	0.921 3	0.850 1	0.750 0	0.670 1	0.845 0	0.772 2
RMCEIN _{w/o} att	0.894 1	0.829 2	0.759 2	0.678 2	0.844 2	0.761 3
RMCEIN _{w/o} nei	0.910 2	0.843 2	0.769 0	0.685 3	0.852 1	0.770 1
RMCEIN _{w/o} IG	0.903 2	0.835 1	0.752 3	0.671 1	0.848 1	0.764 2
RMCEIN	0.928 5	0.861 0	0.774 3	0.688 5	0.859 5	0.780 2

入的对比视图,其推荐效果显著下降,这是随机删除部分三元组可能导致重要的知识丢失。说明引入服从正态分布的弱噪声来增强项目邻居嵌入能有效地缓解知识的丢失和减少知识噪声;在三个数据集上去掉异构传播中的协同传播(RMCEIN_{w/o}IG)将降低模型的推荐性能,说明忽略用户-项目协同信号导致部分重要的项目丢失。综上,本文所提模块或技术都是必要的,消去任何部分都会导致推荐性能下降。

6.3 项目邻居增强的分析

为了探究项目邻居增强对RMCEIN方法中用户和项目邻居的影响,分别设计以下方案:(1)用户和项目邻居都不引入数据增强方法,记为RMCEIN-N。(2)用户和项目邻居都采用数据增强方法,记为RMCEIN-UI。(3)用户邻居采用数据增强方法,记为RMCEIN-U。(4)项目邻居采用数据增强方法,记为RMCEIN-I。为了验证上述各方案的有效性,在Book-Crossing和Last.FM数据集中进行若干次实验,实验结果如表5所示。

分析表5可知,对邻居采用数据增强方法能够带来一定的推荐性能提升。说明对比学习能力提升推荐性能。此外,仅项目邻居嵌入(RMCEIN-I)增强的整体性能最佳,由于KG是项目关联的外部知识库,而KG丰富用户的邻

表5 两个数据集中邻居增强方法对比

Table 5 Comparison of neighbor enhancement methods in two datasets

模型	Book-Crossing		Last.FM	
	AUC	F1	AUC	F1
RMCEIN-N	0.750 8	0.670 1	0.845 5	0.772 2
RMCEIN-UI	0.770 5	0.686 4	0.850 3	0.770 7
RMCEIN-U	0.772 7	0.690 7	0.847 3	0.778 2
RMCEIN-I	0.774 3	0.688 5	0.859 5	0.780 2

居有限。因此,项目邻居嵌入增强通过对比学习能带来明显提升。

6.4 参数灵敏度分析

噪声 ϵ 的大小探究噪声的最佳范围, ϵ 取值为 $[0, 0.05, 0.10, 0.15, 0.20]$,如图5所示。

在图5中,本模型在 $[0.10, 0.10, 0.15]$ 时,在Last.FM、Book-Crossing、MovieLens-1M数据集上,获得最佳性能。若没有添加噪声($\epsilon=0$),发现性能明显下降。当太大($\epsilon=0.2$)或太小($\epsilon=0.05$)时,性能也会下降。验证了适当的添加噪声能够使数据分布均匀,有利于提升性能。

温度影响 τ 根据现有的对比学习工作^[21]所述,公式(12)中定义的温度 τ 在对比学习中起着重要作用。为了研究 τ 的影响,在 $\{0.05, 0.1, 0.15, 0.2, 0.25\}$ 范围内改变值,如图6所示。在 $\tau=0.15$ 时可获得令人满意的推荐性能。当 τ 的值过大时,推荐性能不佳,这与以往的工作结论一致^[20]。说明 τ 能调控学习到的项目嵌入在嵌入空间的均匀性。

模型深度的影响模型的深度 L 表示邻居的层数,为了研究模型深度的影响,本文在 $L=\{1, 2, 3\}$ 范围内改变,并在表6中展示了MovieLens-1M、Book-Crossing和Last.FM数据集的性能比较。

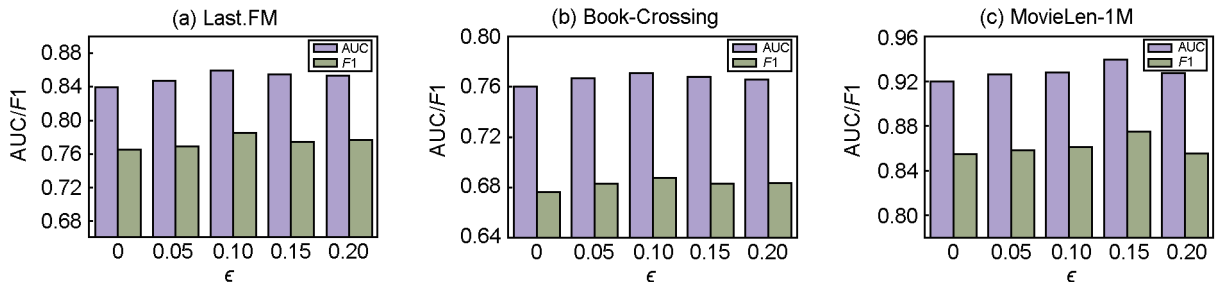


图5 三个数据集中噪声 ϵ 影响

Fig. 5 The influence of noise ϵ in the three datasets

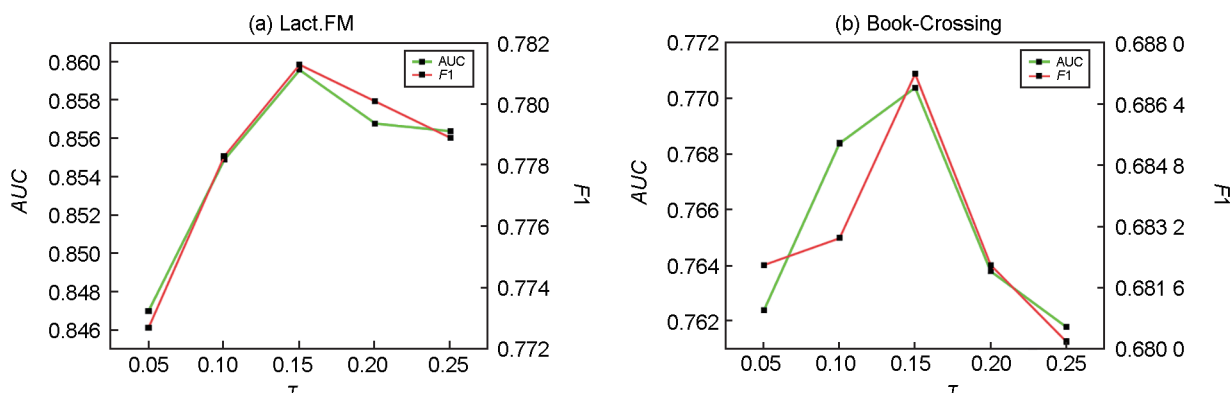
图6 在Last.FM和Book-Crossing数据集中温度 τ 的影响Fig. 6 Effect of temperature τ in Last.FM and Book-Crossing datasets

表6 在三个数据集中层数的影响

Table 6 Effect of the number of layers (L) in the three datasets

层数	MovieLens-1M		Book-Crossing		Last.FM	
	AUC	F1	AUC	F1	AUC	F1
$L=1$	0.922 3	0.855 8	0.765 4	0.681 2	0.850 0	0.768 0
$L=2$	0.927 5	0.860 7	0.774 3	0.688 5	0.859 5	0.780 2
$L=3$	0.928 5	0.861 0	0.764 3	0.683 0	0.853 1	0.775 2

表6表明,当 $L=3,2,2$ 时,在MovieLens-1M、Book-Crossing和Last.FM中RMCEIN表现最佳。说明在2层或3层中聚合图中邻居信息是合适距离,进一步堆叠更多层只会引入更多噪声。

7 结论

本文探索对比学习在基于知识图谱的推荐方法中的应用,提出一种项目邻居信息对比增强的推荐方法,对项目邻居特征采用项目邻居数据增强,以减少项目邻居聚合包含的噪声,并引入对比学习来增强监督信号。通过CTR和Top-K两个评测指标来验证本文的有效性。重点探究了项目的数据增强,通过一系列实验发现仅项目邻居嵌入增强效果最佳。

未来,考虑引入社交网络探索用户的数据特征增强。此外,对比学习中的温度参数需要手动设置,可以考虑自适合的温度参数调控。

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: ACM, 2017: 173-182. DOI: 10.1145/3038912.3052569.
- [2] CHEN J Y, ZHANG H W, HE X N, *et al.* Attentive Collaborative Filtering: Multimedia Recommendation with Item- and Component-level Attention[C]//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2017: 335-344. DOI: 10.1145/3077136.3080797.
- [3] WANG H W, ZHANG F Z, HOU M, *et al.* SHINE: Signed Heterogeneous Information Network Embedding for Sentiment Link Prediction[C]//Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. New York: ACM, 2018: 592-600. DOI: 10.1145/3159652.3159666.
- [4] JAMALI M, ESTER M. A Matrix Factorization Technique with Trust Propagation for Recommendation in Social Networks[J]. *Recsys'10 Proc 4th ACM Conf Recomm Syst*, 2010: 135-142. DOI: 10.1145/1864708.1864736.
- [5] 季德强,王海荣,李明亮,等.融合用户-项目的邻居实体表示推荐方法[J].中文信息学报,2022,36(9):112-119. DOI: 10.3969/j.issn.1003-0077.2022.09.012.
- [6] JI D Q, WANG H R, LI M L, *et al.* Incorporating User-item Neighbor Entity for Recommendation[J]. *J Chin Inf Process*, 2022, 36(9): 112-119. DOI: 10.3969/j.issn.1003-0077.2022.09.012.
- [7] WANG H W, ZHANG F Z, WANG J L, *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. New York: ACM, 2018: 417-426. DOI: 10.1145/3269206.3271739.
- [8] TANG X L, WANG T Y, YANG H Z, *et al.* AKUPM: Attention-enhanced Knowledge-aware User Preference Model for Recommendation[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 1891-1899. DOI: 10.1145/3292500.3330705.
- [9] LIN Y, XU B, FENG J J, *et al.* Knowledge-enhanced Recommendation Using Item Embedding and Path Attention

- [J]. *Knowl Based Syst*, 2021, **233**: 107484. DOI: 10.1016/j.knosys.2021.107484.
- [9] WANG H W, ZHAO M, XIE X, *et al.* Knowledge Graph Convolutional Networks for Recommender Systems[C]//WWW '19: The World Wide Web Conference. New York: ACM, 2019: 3307–3313. DOI: 10.1145/3308558.3313417.
- [10] WANG H W, ZHANG F Z, ZHANG M D, *et al.* Knowledge-aware Graph Neural Networks with Label Smoothness Regularization for Recommender Systems [C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 968–977. DOI: 10.1145/3292500.3330836.
- [11] 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. New York: ACM, 2019: 950–958. DOI: 10.1145/3292500.3330989.
- [12] 曹宗胜, 许倩倩, 李朝鹏, 等. 基于对偶四元数的协同知识图谱推荐模型[J]. 计算机学报, 2022, **45**(10): 2221–2242. DOI: 10.11897/SP.J.1016.2022.02221.
- CAO Z S, XU Q Q, LI Z P, *et al.* Dual Quaternion Based Collaborative Knowledge Graph Modeling for Recommendation[J]. *Chin J Comput*, 2022, **45**(10): 2221–2242. DOI: 10.11897/SP.J.1016.2022.02221.
- [13] WANG Z, LIN G Y, TAN H B, *et al.* CKAN: Collaborative Knowledge-aware Attentive Network for Recommender Systems[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 219–228. DOI: 10.1145/3397271.3401141.
- [14] XU Z M, LIU H L, LI J, *et al.* CKGAT: Collaborative Knowledge-aware Graph Attention Network for Top-N Recommendation[J]. *Appl Sci*, 2022, **12**(3): 1669. DOI: 10.3390/app12031669.
- [15] QIAN F L, ZHU Y H, CHEN H, *et al.* Reduce Unrelated Knowledge through Attribute Collaborative Signal for Knowledge Graph Recommendation[J]. *Expert Syst Appl*, 2022, **201**: 117078. DOI: 10.1016/j.eswa.2022.117078.
- [16] DAI Q, WU X M, FAN L, *et al.* Personalized Knowledge-aware Recommendation with Collaborative and Attentive Graph Convolutional Networks[J]. *Pattern Recognit*, 2022, **128**: 108628. DOI: 10.1016/j.patcog.2022.108628.
- [17] CHEN Y K, YANG M L, ZHANG Y X, *et al.* Modeling Scale-free Graphs with Hyperbolic Geometry for Knowledge-aware Recommendation[C]//Proceedings of the Fifteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2022: 94–102. DOI: 10.1145/3488560.3498419.
- [18] WANG X, HUANG T L, WANG D X, *et al.* Learning Intents Behind Interactions with Knowledge Graph for Recommendation[C]//Proceedings of the Web Conference 2021. New York: ACM, 2021: 878–887. DOI: 10.1145/3442381.3450133.
- [19] CHEN Y K, YANG Y M, WANG Y J, *et al.* Attentive Knowledge-aware Graph Convolutional Networks with Collaborative Guidance for Personalized Recommendation[C]//2022 IEEE 38th International Conference on Data Engineering (ICDE). Chengdu: IEEE, 2022: 299–311. DOI: 10.1109/ICDE53745.2022.00027.
- [20] ZOU D, WEI W, WANG Z, *et al.* Improving Knowledge-aware Recommendation with Multi-level Interactive Contrastive Learning[C]//Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta: CIKM, 2022: 2817–2826. DOI: 10.1145/3511808.3557358.
- [21] QIAN F, ZHU Y, CHEN H, *et al.* Reduce Unrelated Knowledge Through Attribute Collaborative Signal for Knowledge Graph Recommendation[J]. *Expert Systems with Applications*, 2022, **201**: 117078. DOI: 10.1016/j.eswa.2022.117078.