

## 基于知识感知的图优化推荐模型

罗旭阳, 谭智一

引用本文

罗旭阳, 谭智一. [基于知识感知的图优化推荐模型](#)[J]. 计算机科学, 2025, 52(7): 103-109.

LUO Xuyang, TAN Zhiyi. [Knowledge-aware Graph Refinement Network for Recommendation](#)[J].

Computer Science, 2025, 52(7): 103-109.

---

## 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)**

[基于跨模态超图优化学习的多模态情感分析](#)

Cross-modal Hypergraph Optimisation Learning for Multimodal Sentiment Analysis

计算机科学, 2025, 52(7): 210-217. <https://doi.org/10.11896/jsjcx.240600127>

[基于脑网络连通性和脑电微状态的情感识别](#)

Emotion Recognition Based on Brain Network Connectivity and EEG Microstates

计算机科学, 2025, 52(7): 201-209. <https://doi.org/10.11896/jsjcx.240500087>

[基于YOLOv8增强的目标检测算法及其应用规范](#)

Object Detection Algorithm Based on YOLOv8 Enhancement and Its Application Norms

计算机科学, 2025, 52(7): 189-200. <https://doi.org/10.11896/jsjcx.250100108>

[基于多模态特征对齐的弱对齐RGBT显著目标检测](#)

Weakly-aligned RGBT Salient Object Detection Based on Multi-modal Feature Alignment

计算机科学, 2025, 52(7): 142-150. <https://doi.org/10.11896/jsjcx.240600033>

[融合位置和结构信息的图神经网络的节点学习研究](#)

Research on Node Learning of Graph Neural Networks Fusing Positional and Structural Information

计算机科学, 2025, 52(7): 110-118. <https://doi.org/10.11896/jsjcx.240400093>

# 基于知识感知的图优化推荐模型

罗旭阳 谭智一

南京邮电大学通信与信息工程学院 南京 210003

(1021010616@njupt.edu.cn)

**摘要** 基于知识图谱的推荐模型通过捕捉交互物品在知识图谱上的实体关联,实现对用户偏好的精准建模,从而提高推荐的准确性。然而,现有工作忽略了交互图的噪声问题和稀疏性问题,限制了模型对实体关联的捕捉效率,导致用户偏好建模出现偏差,从而无法获得最优结果。为了解决上述问题,提出了一种基于知识感知的图优化推荐模型(Knowledge-aware Graph Refinement Network, KGRN)。具体来说,首先设计了一个图修剪模块,利用知识图谱的语义信息来动态修剪交互图中的噪声交互;然后设计了一个图构建模块来缓解交互图的数据稀疏性,提高模型挖掘用户偏好的实体能力,增强用户偏好建模。为了验证 KGRN 的有效性,在 3 个基准数据集上进行了对比实验。相较于现有模型, KGRN 在 MovieLens-1M 上的表现提升了 2.97%,在 Amazon-Book 上的表现提升了 1.69%,在 BookCrossing 上的表现提升了 2.22%。实验结果证明了所提模型的有效性。

**关键词**: 图神经网络; 知识图谱; 特征学习; 推荐系统; 特征融合

**中图分类号** TP391

## Knowledge-aware Graph Refinement Network for Recommendation

LUO Xuyang and TAN Zhiyi

School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract** Knowledge graph-based recommendation models achieve accurate user preference modeling by capturing entity associations of interaction items on the knowledge graph, thereby enhancing recommendation accuracy. However, existing research ignores the noise and sparsity issues in the interaction graph, which limits the model's ability to capture entity associations and leads to biased, ultimately leading to suboptimal results. To address these issues, this paper proposes a model named knowledge-aware graph refinement network(KGRN). Specifically, a graph pruning module is designed that utilizes semantic information from the knowledge graph to dynamically prune noisy interactions in the interaction graph. Additionally, a graph construction module is developed to mitigate data sparsity in the interaction graph, enhance the model's capability to identify user preference entities, and improve user preference modeling. Comparative experiments are conducted on three benchmark datasets to evaluate the effectiveness of KGRN. Compared to existing models, KGRN achieves performance improvements of 2.97% on MovieLens-1M, 1.69% on Amazon-Book, and 2.22% on BookCrossing, demonstrating the effectiveness of the proposed model.

**Keywords** Graph neural networks, Knowledge graphs, Feature Learning, Recommendation systems, Feature fusion

## 1 引言

在信息爆炸的时代,推荐系统已经成为解决信息过载问题的重要工具,它能够帮助用户从海量物品信息中快速选择符合其兴趣的物品。而知识图谱(Knowledge Graph, KG)作为一种结构化的辅助信息,其丰富的结构和语义信息已被证明可显著提高推荐的准确性<sup>[1-2]</sup>。

借助知识图谱进行推荐的关键在于知识图谱信息和用户-物品交互图的融合。早期的工作<sup>[1,3-4]</sup>是将知识图谱中的

节点和边转换为低维向量,利用交互图将它们作为上下文信息合并到推荐模型中。一些后续的研究<sup>[5-7]</sup>利用用户历史交互生成元路径,然后遍历知识图谱中其他节点的连接以提取相关语义信息,推断用户兴趣。例如,元路径“用户→电影 A→导演→电影 B”揭示了用户对电影 B 的潜在兴趣。近期工作<sup>[2,8-11]</sup>则致力于设计基于图神经网络的端到端模型,通过迭代地合并邻域信息(包括交互图的用户、物品信息,以及知识图谱的属性、关系信息)增强节点嵌入,从而捕获复杂的用户偏好。

到稿日期:2024-06-20 返修日期:2024-12-03

基金项目:国家自然科学基金(62325206,61936005);江苏省重点研发计划(BE2023016-4);江苏省自然科学基金(BK20210595)

This work was supported by the National Natural Science Foundation of China(62325206,61936005), Key Research and Development Program of Jiangsu Province(BE2023016-4) and Natural Science Foundation of Jiangsu Province(BK20210595).

通信作者:谭智一(tzy@njupt.edu.cn)

尽管上述方法取得了初步成效,但之前的大多数工作都忽略了两个问题,从而导致了次优结果。1)交互图中存在噪声连接边。在构建交互图时,用户的偏好选择会影响节点之间的连接方式。如果用户错误或粗心地进行了物品交互,会导致用户与不符合其偏好的物品产生连接,从而形成噪声连接边。2)基于知识图谱的推荐模型通过捕捉交互物品在知识图谱上的实体关联,向用户推荐相关物品。然而,稀疏的用户交互使得模型难以准确捕捉用户的行为模式。以电影推荐为例,科幻电影爱好者观看了诺兰导演的科幻电影《星际穿越》后,当其想观看下一部科幻电影时,模型却可能向他推荐诺兰导演的另一部超级英雄电影《黑暗骑士》。因为根据该用户稀疏的交互行为,模型可能错误地将导演等实体信息作为用户偏好,而不是关注电影类型等实体信息。

为了缓解上述问题,本文提出了基于知识感知的图优化模型 KGRN,通过对原始图结构进行优化来提高模型性能。首先,将用户-物品交互图与知识图谱相结合,扩充用户和物品的语义,强化用户偏好的捕捉效果;其次,设计图修剪模块,根据知识图谱中用户和物品之间的结构相似性来估计交互的可靠性,并采取动态剪枝的方法来获取去噪的交互图,从而使模型能够进行精准建模;然后,设计了一个图构建模块来扩展用户交互表征,挖掘用户的潜在偏好,从而使模型能更准确地理解用户需求。为了确保扩展的用户交互符合用户偏好,本文设计了一个基于结构一致性的辅助自监督任务,通过建模去噪交互图和偏好增强交互图的结构,进一步优化了用户偏好的表示。

本文的主要贡献如下:

- 1)提出了一个基于知识感知的图优化模型,其利用知识图谱信息对原始图结构进行优化来提高推荐性能。
- 2)提出了两个模块:图修剪模块,旨在通过消除噪声交互来准确建模用户偏好;图构建模块,通过优化图结构进一步优化用户表示的偏好表达。
- 3)对3个数据集进行了广泛的实验,实验结果表明 KGRN 优于现有模型;进一步的消融分析,证明了关键组件的合理性。

## 2 相关工作

### 2.1 基于知识图谱的推荐方法

现有的基于知识图谱的推荐方法可以大致分为3类:基于嵌入的方法、基于路径的方法和基于传播的方法。基于嵌入的方法<sup>[1,3-4]</sup>通常利用知识图嵌入方法,例如 TransE<sup>[12]</sup>和 TransH<sup>[13]</sup>,通过转换约束来学习用户和物品表征。基于路径的方法<sup>[5-7]</sup>通过知识图和交互图连接用户-物品节点的元路径来解释用户-物品交互,然后使用这些元路径对用户偏好进行建模。KR-GCN<sup>[14]</sup>通过基于转换的策略来计算路径三元组分数,然后设计一种路径级自注意力机制来区分不同路径对推荐结果的贡献,从而增强用户偏好建模。Zhao等<sup>[15]</sup>提出的 AGRE 模型,通过编码用户与物品之间的多条路径,并深入考虑这些路径之间的关联性,提升了对复杂用户行为模式的捕捉能力。基于传播的方法<sup>[2,8-11]</sup>通过将路径特征合并到

基于嵌入的方法中来执行推荐。RippleNet<sup>[8]</sup>借助知识图谱连接迭代地扩展用户兴趣,挖掘用户对物品的潜在偏好。KGAT<sup>[2]</sup>通过连续的卷积运算更新节点嵌入,完成用户-物品对之间高阶连接的建模。HAKG<sup>[11]</sup>将节点嵌入映射到双曲空间并设计消息聚合机制,以获得用户和物品的最终表征。HIKE<sup>[16]</sup>挖掘知识图谱中不同粒度级别的信息,并从中提取监督信号,以指导模型对物品特征与用户个性化偏好的学习。RAKCR<sup>[17]</sup>旨在从用户评论中挖掘细粒度的个性化特征,并通过对齐知识图谱实体节点与用户节点的特征,实现用户对特定物品的偏好建模。尽管这些方法已经取得了显著的成功,但它们没有考虑交互图的噪声与稀疏性。

### 2.2 图神经网络

图神经网络(Graph Neural Network, GNN)在推荐系统领域展现了巨大潜力。GNN通过其独有的信息聚合机制,能够将多跳邻居信息融入到节点嵌入中,从而为用户和物品生成更准确的表征。具体而言,NGCF<sup>[18]</sup>和 LightGCN<sup>[19]</sup>等模型捕获了用户行为特征,并通过在用户-物品交互图中迭代执行消息聚合来更新用户和物品的嵌入表征。然而,这种消息聚合机制可能会导致噪声在整个图中传播。为了解决噪声传播问题,Wang等<sup>[20]</sup>和 Dai等<sup>[21]</sup>分别通过调整损失函数的值和设置伪标签来减少噪声的负面影响。Tian等<sup>[22]</sup>使用去噪策略减少噪声的负面影响,同时还设计了多样性增强模块来保持推荐的多样性。随着知识图谱推荐技术的不断发展,利用知识图谱引导去噪的工作也备受关注。例如,Mu等<sup>[23]</sup>通过在知识层面替换物品的相关知识,更深入地构建反事实交互,以减轻历史交互中的虚假相关性。然而,该方法只替换了物品部分的相关知识,没有从物品整体相关知识的角度思考用户与物品交互的原因,需要额外设定奖惩函数。与之前的研究不同,本文侧重于从整体角度出发,让模型自主学习知识图谱语义,以抵消噪声交互的负面影响。此外,本文还对交互图进行了优化,在优化交互图上进行消息传递,从而进一步增强用户和项目表示。

## 3 定义

**定义 1(知识图谱)** 知识图谱是一种特殊的网络结构,以现实世界中的实体作为知识图节点,实体之间的关系作为连接边。因此,三元组是知识图谱的最小单元,记为 $(h, r, t)$ ,其中 $h, r, t$ 分别代表头节点、关系和尾节点。使用 $G_1 = (V, E)$ 来形式化表示知识图谱,其中 $V$ 代表节点集, $E$ 代表边集。

**定义 2(用户交互图)** 用户交互图是一种用于表示推荐系统中用户、物品交互关系的图结构,其中节点表示用户或物品,连接边表示用户是否对物品发生过交互。在交互图 $G_0$ 中,如果用户 $u$ 与物品 $i$ 存在交互,则 $y_{ui} = 1$ ;反之, $y_{ui} = 0$ 。

**定义 3(推荐任务)** 推荐任务是根据给定的交互图 $G_0$ 和知识图谱 $G_1$ ,学习一个能够预测用户与物品交互概率的函数。

## 4 KGRN 模型

本章将详细介绍所提出的模型,其总体结构如图1所示。KGRN由3个组件构成:嵌入层、图优化层、消息聚合层。




图1 KGRN模型的整体框架

Fig. 1 Overall frame of KGRN

#### 4.1 嵌入层

在知识图谱中,当用户对某个实体(如物品、物品属性等)存在偏好时,这种偏好信息可以通过知识图谱中的实体关联进行传递和扩散。因此,本文期望模型能够捕捉物品实体附近的邻居信息,以增强用户对物品实体的偏好建模。

值得注意的是,相同的尾节点  $t$  在不同的关系  $r$  下对头节点的影响并不相同,且不同的尾节点  $t$  在相同的关系  $r$  下对头节点的影响也不相同。例如:(食神,导演,周星驰)和(食神,参演,周星驰),这两个三元组对电影《食神》进行了不同方面的描述。这两个三元组关系  $r$  发生了变化,导致尾节点“周星驰”对《食神》这部电影的影响不尽相同。类似地,如果关系  $r$  不变,尾节点  $t$  发生变化,不同尾节点也会对头节点造成不同的影响。因此,首先将关系  $r$  与尾节点  $t$  进行融合,使其能够表示三元组携带的不同语义信息;然后聚合头节点所有的邻居语义信息作为物品实体的嵌入表征:

$$e_i^{(1)} = \frac{1}{|\mathcal{N}_i|} \sum_{(r,v) \in \mathcal{N}_i} e_r \odot e_v^{(0)} \quad (1)$$

其中,  $e_r$  和  $e_v^{(0)}$  分别表示关系  $r$  和实体  $v$  的表征向量,  $\odot$  是逐元素乘积,  $\mathcal{N}_i = \{(r,v) | (r,v) \in \mathcal{G}_i\}$  表示物品  $i$  的属性,  $e_i^{(1)}$  表示物品  $i$  的聚合表征向量。

为了捕获用户节点的结构和语义表征,本文对历史交互数据  $\mathbf{R}$  和物品聚合表征  $e_i^{(1)}$  进行编码,以获得用户的组合表征:

$$E_U^S = RE_U^{(1)} \quad (2)$$

其中,  $E_U^S \in \mathbb{R}^{|\mathcal{U}| \times d}$  表示用户的结构和语义的表征矩阵;  $E_U^{(1)} \in \mathbb{R}^{|\mathcal{U}| \times d}$  表示语义信息聚合后的物品表征矩阵。需要注意的是,  $e_i^{(1)}$  和  $e_u^s$  分别对应  $E_U^{(1)}$  的第  $i$  行和  $E_U^S$  的第  $u$  行。

#### 4.2 图细化层

##### 4.2.1 图修剪模块

在真实世界场景下,用户与物品的历史交互并不一定反映用户的真实偏好。例如,用户由于错误或粗心等原因与物

品发生的交互,会向用户交互图引入噪声,影响模型对用户的偏好建模。

针对上述问题,本文提出了一种新颖的图修剪算法,通过识别交互图  $\mathcal{G}_0$  中更可靠的用户-物品交互来直接降低噪声对模型的影响。具体来说,利用第  $i$  行  $E_U^{(1)}$  的  $e_i^{(1)}$  和第  $u$  行  $E_U^S$  的  $e_u^s$  计算余弦相似度,判断用户和物品的结构相似性。由于可靠程度分数为正值,因此将余弦相似度转换为归一化余弦距离,用于估计用户交互的可靠程度:

$$\cos(e_u^s, e_i^{(1)}) = \frac{e_u^s \top e_i^{(1)}}{\|e_u^s\|_2 \cdot \|e_i^{(1)}\|_2} \quad (3)$$

$$c_{ui} = (\cos(e_u^s, e_i^{(1)}) + 1) / 2 \quad (4)$$

其中,  $c_{ui}$  表示用户-物品交互图中连接边的可靠性得分。理想情况下,对于给定的连接边,较高的  $c_{ui}$  分数意味着更高的可靠性,而较低的分则表示需要修剪。最终的可靠性得分用  $\tilde{c}_{ui}$  表示,定义如下:

$$\tilde{c}_{ui} = \Phi(c_{ui} > \beta) \quad (5)$$

其中,  $\Phi(\cdot)$  表示二进制阈值函数,当可靠程度分数超过阈值时返回 1;  $\beta$  表示固定调整阈值。

需要注意的是,由于可靠性得分  $\tilde{c}_{ui}$  会随着训练过程逐渐增加,如果阈值  $\beta$  设为一个固定值,将会在模型训练后期抑制图剪枝操作。受到动态调整思想<sup>[24]</sup>的启发,采用动态阈值函数  $\beta(t)$  进行图结构剪枝,如式(6)所示:

$$\beta(t) = \min(\alpha t, \beta_{\max}) \quad (6)$$

其中,  $\beta_{\max}$  表示阈值上限,  $\alpha$  为调整阈值变化速率的超参数,  $t$  表示迭代次数。

##### 4.2.2 图构建模块

为了缓解交互图的稀疏性,提高模型捕捉用户行为模式的能力,首先利用节点选择方法来识别实体类别;然后根据实体类别对交互图连接进行扩充,以直接缓解数据稀疏性;最后设计了一个基于结构一致性的损失函数,以确保扩充的交互连接能够准确表示用户偏好。

具体来说,首先通过  $\mathbf{e}_u^s$  和  $\mathbf{e}_i^{(1)}$  计算用户  $u$  与每个物品  $i$  之间的相似度;然后按相似度进行高低排序,获得每个用户的前  $M$  个相似物品。值得注意的是,前  $M$  个相似物品中既包括  $y_{ui}=1$  的物品,也包括  $y_{ui}=0$  的物品。因此,从中筛选出  $y_{ui}=0$  的物品,并在去噪后的交互图  $\tilde{G}_0$  中为这些物品构建交互边。

$$s_{ui} = \sigma(\mathbf{e}_u^s \top \mathbf{e}_i^{(1)}) \quad (7)$$

其中,  $\sigma(\cdot)$  是激活函数。为了防止在后续模型训练中出现梯度消失问题,使用 ReLU 函数作为激活函数。

在构建交互边之后,采用注意力机制来优化消息传递。对于  $u \in U, i \in I$ , 如果  $s_{ui}$  大于式(6)描述的阈值  $\beta(t)$ , 则对它们设置连接边并设置连接边权重,从而获得增强交互图  $\tilde{G}_0'$ 。

$$S_{ui} = \begin{cases} s_{ui}, & \text{if } s_{ui} > \beta(t) \\ 0, & \text{else} \end{cases} \quad (8)$$

其中,  $S_{ui} \in \mathbb{R}^{|U| \times |I|}$  为增强交互图  $\tilde{G}_0'$  的权重矩阵,  $s_{ui}$  表示用户  $u$  和物品  $i$  之间的连接边权重,其值对应于权重矩阵  $S_{ui}$  的第  $u$  行第  $i$  列元素。

为了确保增强交互图  $\tilde{G}_0'$  能够捕获用户的潜在偏好,使用重建损失函数对模型进行引导:

$$\mathcal{L}_{\text{recon}} = \|S_{ui} - G_0\|^2 \quad (9)$$

然而,由于  $\tilde{G}_0'$  中大部分元素值为 0, 模型只需要简单输出 0 值元素就能获得较强的交互图重建性能。为了避免这一情况,对每个交互连接  $y_{ui}=1$ , 随机采样了  $P$  个与用户  $u$  无关的节点作为负样本来指导交互图重建。

$$\mathcal{L}_{\text{recon}} = \sum_{(u,i) \in \tilde{G}_0} ((S_{ui} - 1)^2 + \sum_{i'=1}^P (S_{ui'} - 0)^2) \quad (10)$$

其中,  $i'$  表示与用户  $u$  没有交互关系的随机物品,  $\tilde{G}_0$  表示经过图修剪模块处理的去噪交互图。

### 4.3 消息聚合层

受到近期细粒度偏好融合工作的启发,在优化的用户交互图上引入了细粒度偏好向量  $\mathbf{b}_i$  [25], 从而获得更准确和个性化的用户表征。

$$\mathbf{e}_u^{(1)} = \frac{1}{|\mathcal{N}_u|} \sum_{i \in \mathcal{T}} \sum_{i' \in \mathcal{T}} \frac{\exp(\mathbf{b}_i \top \mathbf{e}_u^{(0)})}{\sum_{i' \in \mathcal{T}} \exp(\mathbf{b}_{i'} \top \mathbf{e}_u^{(0)})} \mathbf{b}_i \odot \mathbf{e}_i^{(0)} \quad (11)$$

其中,  $\mathbf{e}_u^{(1)}$  表示用户  $u$  的表征向量,  $\mathbf{e}_u^{(0)}$  和  $\mathbf{e}_i^{(0)}$  分别表示从用户和物品嵌入查找表中获得的用户表征和物品表征,  $\mathcal{T}$  表示细粒度偏好向量集合,  $\mathcal{N}_u = \{i | (u, i) \in \tilde{G}_0'\}$  表示用户  $u$  的历史交互。

为了精确描述用户行为模式,引入独立损失函数来提高偏好向量之间的独立性,促使模型从多个角度解释用户行为。

$$\mathcal{L}_{\text{cos}} = - \sum_{i \in \mathcal{T}} \log \left( \frac{\exp(\cos(\mathbf{b}_i, \mathbf{b}_i) / \eta)}{\sum_{i' \in \mathcal{T}} \exp(\cos(\mathbf{b}_{i'}, \mathbf{b}_i) / \eta)} \right) \quad (12)$$

其中,  $\eta$  是调节归一化效果的超参数。

### 4.4 模型预测与优化

获得增强交互图  $\tilde{G}_0'$  后,按照式(1)和式(11)描述的方式进行消息聚合并获得最终的嵌入表征。随后,使用内积来确定用户对目标物品的偏好得分:

$$\hat{y}_{ui} = \left( \sum_{l=0}^L \mathbf{e}_u^{(l)} \right) \top \left( \sum_{l=0}^L \mathbf{e}_i^{(l)} \right) \quad (13)$$

其中,  $\mathbf{e}_u^{(l)}$  和  $\mathbf{e}_i^{(l)}$  分别表示用户  $u$  和物品  $i$  的嵌入表征,并且它们记住了  $l-1$  跳的邻居信息;  $L$  是控制邻域范围的超参数。

本文通过最小化以下目标函数来学习模型参数,为了保持表达的简洁性,省略了 L2 正则化术语的符号:

$$\mathcal{L}_{\text{all}} = \sum_{(u,i,j) \in O} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) + \mu \mathcal{L}_{\text{cos}} + \gamma \mathcal{L}_{\text{recon}} \quad (14)$$

其中,  $O = \{(u, i, j) | (u, i) \in O^+, (u, j) \in O^-\}$  表示训练数据集,  $O^+$  表示用户历史交互,  $O^-$  表示未观察到交互的用户物品对。  $\mu, \gamma$  是两个控制损失函数影响的参数,它们的取值范围为  $1 \times 10^{-5} \sim 5 \times 10^{-3}$ 。

## 5 实验与分析

### 5.1 数据集

本文在 3 个公共数据集上进行实验,分别是 MovieLens-1M (Movie), Amazon-Book (Amazon), BookCrossing (Book)。对于每个数据集,按照 8:1:1 的比例将用户的历史交互记录划分为训练集、验证集和测试集。表 1 列出了 3 个数据集的基本统计信息。

表 1 数据集统计信息

Table 1 Datasets statistics information

|     | Movie | Amazon  | Book    |        |
|-----|-------|---------|---------|--------|
| 交互图 | 用户    | 6 034   | 75 335  | 2 618  |
|     | 物品    | 3 104   | 7 985   | 560    |
|     | 交互    | 832 299 | 377 597 | 4 296  |
| 知识图 | 实体    | 13 908  | 21 683  | 9 913  |
|     | 关系    | 50      | 40      | 22     |
|     | 三元组   | 483 000 | 514 122 | 77 914 |

为了保证数据质量,在 Movie 和 Amazon 数据集上只保留了交互次数不少于 10 次的用户与物品,Book 数据集则使得每个用户和物品至少有 3 次交互。表 1 只统计了规范关系的数目,并且在实验中人为生成了相反关系的三元组。由于上述 3 个数据集都是用户对于物品的评分数据集,需要将这 3 个数据集的评级转化为隐式反馈。因此在 Movie 和 Amazon 中,本文将高于 3 分的评分视为正例,其他视为负例。此外,对于稀疏的 Book 数据集,将高于 5 分的评分视为正例,其他视为负例。

### 5.2 评价指标和参数设置

为了评估所提 KGRN 模型的推荐性能,本文采取常用的前  $K$  个召回率 (Recall@K) 和前  $K$  个归一化折损累计增益 (NDCG@K) 作为评估指标。其中,Recall 衡量的是模型找回相关物品的能力, NDCG 是衡量排序质量的指标。在实验中,设置  $K$  的值为 10。

对于基线方法,本文要么使用提供的源代码实现,要么使用 RecBole [26] 进行复现。为了公平比较,将嵌入大小和批量大小分别设置为 64 和 4 096,并根据原始论文调整超参数。对 KGRN 和基线方法都采用 Adam 优化器。对于提出的 KGRN,设置学习率调整区间为  $[1 \times 10^{-4}, 1 \times 10^{-1}]$ , 层数  $L$  区间为  $\{2, 3, 4\}$ , 阈值固定为 0.2, 损失系数  $\mu, \gamma, \lambda$  的调整区间为  $\{1 \times 10^{-5}, 5 \times 10^{-5}, 1 \times 10^{-4}, 5 \times 10^{-4}, 1 \times 10^{-3}, 5 \times 10^{-3}\}$ , top- $M$  的调整区间为  $\{5, 10, 15, 20, 25\}$ 。

### 5.3 实验结果与分析

为了验证模型的有效性,将 KGRN 与 6 个具有代表性的主流模型进行了对比实验。

1) RippleNet(2018)<sup>[8]</sup>:利用知识图谱的结构信息,沿着交互物品连接边,在知识图上传播用户偏好。

2) KGNN-LS(2019)<sup>[27]</sup>:将图神经网络应用于知识图谱上,聚合物品的邻居信息,用于计算个性化物品嵌入。

3) KGAT(2019)<sup>[23]</sup>:以端到端的方式建模了知识图上的高阶连接,通过堆叠卷积层来传播邻居嵌入,优化节点的表征学习。

4) CKAN(2020)<sup>[9]</sup>:利用知识图上的知识关联传播协作信号,并选用知识图上的实体来表征用户与物品。

5) KGIN(2021)<sup>[10]</sup>:利用知识图谱中的关系分解用户的交互意图,并将用户意图嵌入到用户嵌入中,保留知识图谱中远距离连接的语义信息。

6) CGKR(2022)<sup>[23]</sup>:通过替换知识图谱连接生成反事实交互,并设计奖惩函数来帮助模型降低噪声对推荐的影响。

实验结果如表 2、表 3 所列,其中最优结果用粗体表示,次优结果用下划线表示。

表 2 Recall@10 性能对比

Table 2 Comparison of Recall@10 performance

| Model     | Movie         | Amazon        | Book          |
|-----------|---------------|---------------|---------------|
| RippleNet | 0.1284        | 0.0964        | 0.1262        |
| KGNN-LS   | 0.1529        | 0.1366        | 0.1058        |
| KGAT      | 0.1745        | 0.1428        | 0.1491        |
| CKAN      | 0.0937        | 0.1630        | 0.1483        |
| KGIN      | <u>0.1782</u> | 0.1857        | 0.1511        |
| CGKR      | 0.1767        | <u>0.2005</u> | <u>0.1621</u> |
| Ours      | <b>0.1835</b> | <b>0.2039</b> | <b>0.1657</b> |
| %imp.     | 2.97          | 1.69          | 2.22          |

表 3 NDCG@10 性能对比

Table 3 Comparison of NDCG@10 performance

| Model     | Movie         | Amazon        | Book          |
|-----------|---------------|---------------|---------------|
| RippleNet | 0.1843        | 0.0545        | 0.0806        |
| KGNN-LS   | 0.2128        | 0.0773        | 0.0520        |
| KGAT      | <u>0.2400</u> | 0.0921        | 0.0924        |
| CKAN      | 0.1056        | 0.0968        | 0.0958        |
| KGIN      | 0.2371        | 0.1117        | <u>0.1042</u> |
| CGKR      | 0.2387        | <u>0.1120</u> | 0.1034        |
| Ours      | <b>0.2425</b> | <b>0.1239</b> | <b>0.1083</b> |
| %imp.     | 1.96          | 10.62         | 3.93          |

首先,KGRN,KGAT 和 KGIN 在所有数据集上的评价指标均优于 KGNN-LS 和 RippleNet。这表明 KGRN,KGAT 和 KGIN 不仅仅利用了知识图谱的结构信息,而且通过挖掘知识图谱内部的关联来准确地捕获了用户偏好。

其次,KGRN 在 3 个数据集上的所有指标均显著优于 KGAT 和 KGIN。这说明仅依赖原始的交互图和知识图谱无法充分表达用户对物品的偏好,导致 KGAT 和 KGIN 只能达到次优效果。而 KGRN 通过修剪和重构图结构,能够更准确地捕获用户的偏好。

最后,KGRN 在各个数据集上的指标均优于 CGKR,且在 Amazon 数据集上的 Recall 和 NDCG 指标分别提升了 1.69% 和 10.62%。这表明在推荐系统中,相比于局部考虑

物品的拓扑结构,整体考虑物品在知识图谱上的拓扑结构能够更有效地提高推荐性能。

### 5.4 消融实验

为了验证本文提出的图修剪模块和图构建模块的有效性,本节比较了 3 种模型变体的性能:1) w/o GP 是删除图修剪模块的 KGRN 变体;2) w/o GC 是删除图构建模块的 KGRN 变体;3) w/o both 是删除图修剪模块和图构建模块的 KGRN 变体。评价指标采用 Recall@10 和 NDCG@10,实验结果如图 2 所示。




图 2 消融实验

Fig. 2 Ablation study

1) 与 w/o both 相比,w/o GP 性能更优,说明图构建模块能够有效地捕提高阶信息,得到更好的嵌入表征,提升推荐性能。

2) 与 w/o both 相比,w/o GC 性能更优,说明图修剪模块能够有效地修剪噪声连接边,更加准确地融合物品信息,提升模型推荐效果。

3) w/o both 在两个数据集上的指标均低于 w/o GP 和 w/o GC,说明图修剪模块和图构建模块单独加在推荐模型上都有利于提升推荐模型的性能。

综上所述,本文提出的图修剪模块与图构建模块能够增强模型推荐性能,对最终推荐效果产生积极影响。具体而言,图修剪模块旨在减少噪声信息对推荐结果的干扰,实现更精准的偏好建模,从而提高推荐性能;而图构建模块则通过深入挖掘用户潜在偏好,理解用户需求,以此提升模型的整体性能。

### 5.5 重要参数对模型的影响

本节对 KGRN 进行了一系列详细分析,以进一步证实其稳健性和有效性。

1) 比较了 KGRN 在不同层  $L$  和超参数  $M$  下的性能,结果如图 3、图 4 所示。




图 3 Book 数据集上的 KGRN 性能比较

Fig. 3 Performance comparison of KGRN on Book dataset

在 Book 数据集中, 逐渐增加  $L$  值, 模型的预测性能呈线性增长趋势。而在 Amazon 数据集中, 增加  $L$  值, 模型性能逐渐下降。实验结果表明, 在稀疏的 Book 数据集中, 高阶连通性与二阶连通性互补, 因此通过增加  $L$ , 能够获得更好的节点表征。在较为稠密的 Amazon 数据集中, 由于大多数知识图谱连接已经在  $L=2$  时就已经被捕获, 因此继续增加  $L$  的值会降低模型的性能。对于超参数  $M$ , 通过分析 KGRN 在两个数据集上的实验结果可以发现, 逐步增加  $M$  通常会提高性能, 然而在稀疏数据集上设置超过 20 的值则会带来不利影响。因此, 为了最大限度地提高模型的推荐性能, 必须对  $M$  进行优化调整。




图 4 Amazon 数据集上的 KGRN 性能比较

Fig. 4 Performance comparison of KGRN on Amazon dataset

2) 为了验证图修剪模块的有效性, 通过向两个真实世界数据集注入噪声来构建两个合成数据集。这两个数据集分别被命名为“Polluted Movie”(P-Movie1M) 和“Polluted Amazon”(P-Amazon)。具体来说, 随机抽取 5% 的用户-物品交互记录, 并用随机生成的噪声交互记录替换它们, 以模拟真实世界的污染数据。评价指标采用 Recall@10 和 NDCG@10, 实验结果如表 4 所列。

表 4 污染数据集上的性能对比

Table 4 Performance comparison on polluted dataset

| Model  | P-Movie1M |        | P-Amazon |        |
|--------|-----------|--------|----------|--------|
|        | Recall    | NDCG   | Recall   | NDCG   |
| KGIN   | 0.1695    | 0.2280 | 0.1656   | 0.1050 |
| CGKR   | 0.1653    | 0.2332 | —        | —      |
| w/o GP | 0.1730    | 0.2342 | 0.1749   | 0.1046 |
| KGRN   | 0.1778    | 0.2409 | 0.1859   | 0.1104 |

与 KGIN, CGKR 和 w/o GP 相比, KGRN 在高噪声环境下表现出更好的推荐性能, 证明了图修剪模块的去噪能力。当向 Amazon 数据集添加噪声时, CGKR 占用了过多显存, 无法完成相关实验, 因此表 4 中的相关数据留空, 以待将来处理。

3) 对 KGRN 的构建损失系数  $\gamma$  进行了详尽的实验研究, 实验结果如图 5 所示。具体而言, 在稠密的 Movie 数据集中, 较小的构建损失系数就能促进模型性能的提升; 而在数据稀疏的 Book 数据集中, 则需要较大的构建损失系数才能获得较好的模型性能。因此, 当考虑将 KGRN 应用于其他类型的稠密或稀疏数据集时, 需要根据数据集自身特性来设置合适的构建损失系数。对于稠密数据集, 可以尝试使用较小的构建损失系数; 而对于稀疏数据集, 则可能需要设置较大的构建损失系数, 以期获得更好的模型性能。

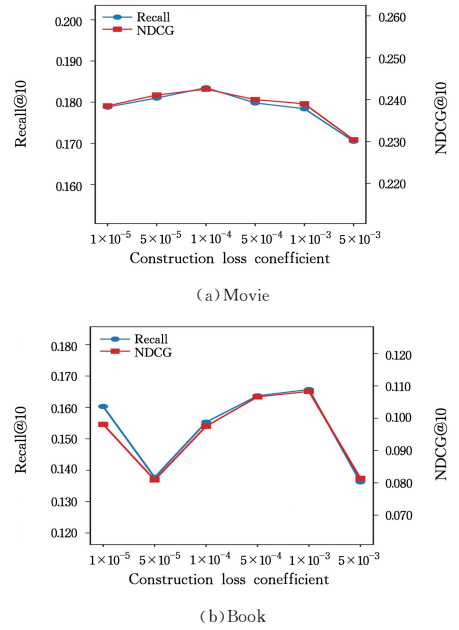


图 5 构建损失系数对 KGRN 性能的影响

Fig. 5 Impact of construction loss coefficient on KGRN performance

**结束语** 本文提出一种基于知识感知的图优化推荐模型 (KGRN)。该模型通过知识图谱来去除用户历史交互中的噪声交互, 并利用知识图谱实体信息扩充交互图, 缓解数据稀疏性, 使模型能够准确捕捉用户行为模式, 从而生成更准确的推荐结果。实验结果表明, KGRN 在 3 个数据集上的评价指标均优于现有模型。

本文侧重于静态用户建模, 对用户交互的时序信息考虑较少, 且当前模型算法复杂度偏高, 在一定程度上限制了模型在更广泛领域的应用。后续将致力于开发一种高效的模型框架, 旨在将用户时序信息与知识图谱信息进行有效整合, 从而提供更加精准和实时的推荐服务。

## 参考文献

- [1] WANG H, ZHANG F, XIE X, et al. DKN: Deep Knowledge-Aware Network for News Recommendation[C]// Proceedings of the 2018 World Wide Web Conference on World Wide Web. 2018:1835-1844.
- [2] WANG X, HE X, CAO Y, et al. KGAT: Knowledge Graph Attention Network for Recommendation[C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2019:950-958.
- [3] ZHANG F, YUAN N J, 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. 2016:353-362.
- [4] CAO Y, WANG X, HE X, et al. Unifying Knowledge Graph Learning and Recommendation: Towards a Better Understanding of User Preferences[C]// The World Wide Web Conference. 2019:151-161.
- [5] MA W, ZHANG M, CAO Y, et al. Jointly Learning Explainable Rules for Recommendation with Knowledge Graph[C]// The World Wide Web Conference. ACM, 2019:1210-1221.

- [6] ZHAO H, YAO Q, LI J, et al. Meta-Graph Based Recommendation Fusion over Heterogeneous Information Networks[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2017: 635-644.
- [7] CHEN H, LI Y, SUN X, et al. Temporal Meta-path Guided Explainable Recommendation[C]// Proceedings of the 14th ACM International Conference on Web Search and Data Mining. 2021: 1056-1064.
- [8] WANG H, ZHANG F, 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. ACM, 2018: 417-426.
- [9] WANG Z, LIN G, TAN H, 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. ACM, 2020: 219-228.
- [10] WANG X, HUANG T, WANG D, et al. Learning Intents behind Interactions with Knowledge Graph for Recommendation[C]// Proceedings of the Web Conference 2021. 2021: 878-887.
- [11] DU Y, ZHU X, CHEN L, et al. HAKG: Hierarchy-Aware Knowledge Gated Network for Recommendation [J]. arXiv: 2204.04959, 2022.
- [12] BORDES A, USUNIER N, GARCÍA-DURÁN A, et al. Translating Embeddings for Modeling Multi-relational Data[C]// Proceedings of the 27th International Conference on Neural Information Processing Systems. 2013: 2787-2795.
- [13] WANG Z, LI J Z. Text-Enhanced Representation Learning for Knowledge Graph[C]// Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence. 2016: 1293-1299.
- [14] MA T, HUANG L, LU Q, et al. Kr-gcn: Knowledge-aware reasoning with graph convolution network for explainable recommendation [J]. ACM Transactions on Information Systems, 2023, 41(1): 1-27.
- [15] ZHAO N, LONG Z, WANG J, et al. AGRE: A knowledge graph recommendation algorithm based on multiple paths embeddings RNN encoder [J]. Knowledge-Based Systems, 2023, 259: 110078.
- [16] QIN Y, GAO C, WEI S, et al. Learning from hierarchical structure of knowledge graph for recommendation[J]. ACM Transactions on Information Systems, 2023, 42(1): 1-24.
- [17] CUI Y, YU H, GUO X, et al. RAKCR: Reviews sentiment-aware based knowledge graph convolutional networks for Personalized Recommendation [J]. Expert Systems with Applications, 2024, 248: 123403.
- [18] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019: 165-174.
- [19] HE X, 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. 2020: 639-648.
- [20] WANG W, FENG F, HE X, et al. Denoising Implicit Feedback for Recommendation[C]// Proceedings of the 14th ACM International Conference on Web Search and Data Mining. 2021: 373-381.
- [21] DAI E, AGGARWAL C, WANG S. NRGNN: Learning a Label Noise Resistant Graph Neural Network on Sparsely and Noisily Labeled Graphs[C]// Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2021: 227-236.
- [22] TIAN C, XIE Y, LI Y, et al. Learning to Denoise Unreliable Interactions for Graph Collaborative Filtering[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022: 122-132.
- [23] MU S, LI Y, ZHAO W X, et al. Alleviating Spurious Correlations in Knowledge-aware Recommendations through Counterfactual Generator[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2022: 1401-1411.
- [24] FENG F, HE X, LIU Y, et al. Learning on Partial-Order Hypergraphs[C]// Proceedings of the 2018 World Wide Web Conference on World Wide Web. 2018: 1523-1532.
- [25] WANG Y, TANG S, LEI Y, et al. DisenHAN: Disentangled Heterogeneous Graph Attention Network for Recommendation [C]// Proceedings of the 29th ACM International Conference on Information and Knowledge Management. 2020: 1605-1614.
- [26] ZHAO W X, HOU Y, PAN X, et al. Recbole 2.0: Towards a more up-to-date recommendation library[C]// Proceedings of the 31st ACM International Conference on Information and Knowledge Management. 2022: 4722-4726.
- [27] WANG H, ZHANG F, ZHANG M, 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 and Data Mining. 2019: 968-977.



**LUO Xuyang**, born in 1999, postgraduate. His main research interest is recommendation systems.



**TAN Zhiyi**, born in 1986, Ph.D. lecturer. His main research interests include multimedia data mining, and sequence analysis and prediction.