

罗旭阳. 基于多样关系建模的推荐模型[J]. 智能计算机与应用, 2026, 16(4): 211-218. DOI: 10.20169/j.issn.2095-2163.24060502

基于多样关系建模的推荐模型

罗旭阳

(南京邮电大学通信与信息工程学院, 南京 210003)

摘要: 基于知识图谱的推荐模型利用知识图谱来构建用户与物品的特征表示,但这些方法忽视了知识图谱中关系的长尾分布特性,导致模型对头部关系过拟合,从而影响模型推荐精度。为此本文提出了一种基于多样关系建模的推荐模型,旨在优化对头部与尾部关系的学习过程,进而提升模型的推荐性能。具体来说,模型由知识优化模块和多视角损失函数构成。知识优化模块通过融合软硬策略,深入挖掘知识图谱的语义信息,并采用聚类约束来减少关系种类,从而缓解知识图谱的长尾分布问题。多视角损失函数则基于用户偏好,从多角度出发引导模型学习更准确的嵌入表征,以增强了模型对尾部关系的敏感度。在两个公开数据集上的实验结果表明,本文所提模型可以通过缓解知识图谱长尾分布,提升推荐精度,从而证明模型的有效性。

关键词: 推荐系统; 知识图谱; 长尾分布; 关系建模

中图分类号: TP391.3

文献标志码: A

文章编号: 2095-2163(2026)04-0211-08

Diverse relationship modeling network for recommendation

LUO Xuyang

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

Abstract: Knowledge graph-based recommendation models utilize knowledge graphs to construct embeddings for users and items. However, they fail to consider the long-tail distribution of relationships within knowledge graphs, leading to the overfitting of head relations and a subsequent reduction in the accuracy of recommendations. To address this issue, we propose the Diverse Relationship Modeling Network (DRMN), which is designed to enhance learning across both head and tail relations, thereby improving overall model performance. The DRMN comprises two key components: a knowledge optimization module and a multi-view loss function. The knowledge optimization module addresses the long-tail problem by integrating soft and hard strategies to extract deep semantic insights from the knowledge graph and applying clustering constraints to simplify the relationship variety. Additionally, the multi-view loss function encourages the acquisition of more precise embedding representations from various angles, reflecting user preferences and increasing sensitivity to tail relations. Experimental results on two public datasets have demonstrated that DRMN significantly enhances recommendation accuracy by effectively alleviating the long-tail distribution in knowledge graphs, confirming the effectiveness of the proposed model.

Key words: recommendation systems; knowledge graph; long-tail distribution; relation modeling


0 引言

随着互联网技术的迅猛发展,用户所接触到的数据量呈现爆炸性增长态势。在信息过载的当下,用户想在众多选择中识别并筛选出真正感兴趣的内容变得愈发困难。为解决这一难题,推荐系统(Recommendation systems)应运而生,旨在为用户提供个性化的推荐服务,从而改善用户体验。而知识

图谱(Knowledge Graph, KG)作为一种结构化的辅助信息源,其具备的丰富结构和语义信息已被证明能显著提高推荐的准确性和性能^[1-2]。

目前,基于知识图谱的推荐模型主要使用图神经网络(Graph Neural Network, GNN)来提升推荐性能。图神经网络通过整合目标节点及其多阶邻居的信息,显著提高了推荐的相关性和精确性。然而,这类模型的性能表现往往受限于所依赖的知识图谱数据质量。

具体而言,在实际应用场景中,知识图谱中的关系分布通常存在明显的长尾效应,即少数头部关系频繁出现,而大多数尾部关系的频次相对较低。为直观展现这一分布特征,本文针对 Last.FM 数据集绘制了关系分布图,其中 x 轴表示关系索引, y 轴代表关系出现频次。如图 1(a) 所示,大部分尾部关系频次较低,而仅少数头部关系频次较高。如果模型过度关注这些头部关系而忽略尾部关系,将难以充分利用知识图谱中的全面信息,进而影响推荐的准确性。例如,在图 1(b) 中,电影《终结者》通过“明星”这一头部关系与多个实体相连,可能导致模型倾向于推荐与《终结者》具有相同“明星”关系的其他作品(如施瓦辛格主演的电影 B),而忽视那些缺乏此类共享关系的作品(如电影 A)。



(a) 关系频次分布



(b) 推荐偏差示例

图 1 长尾分布情况示例

Fig. 1 Example of long-tail distribution

针对上述问题,本文提出了一种基于多样关系建模的推荐模型(Diverse Relationship Modeling Network, DRMN),该模型通过优化对头部与尾部关系的学习以提升模型性能。具体来说,模型由融合软硬策略的知识优化模块和多视角损失函数构成。在软策略方面,DRMN 首先采用知识遮蔽机制,对部分知识进行选择性的屏蔽,随后通过重建被遮蔽的知识来增强模型对知识图谱深层语义的洞察能力。在硬策略方面,DRMN 通过提供关系聚类约束减少知识图谱中的关系种类,提高关系的出现频率,以缓解长尾问题。通过软硬策略的结合,DRMN 不仅深入理解了知识图谱的语义,还提升了对尾部关系的学

习能力,从而提高了推荐的准确性。此外,本文还设计了一种多视角损失函数,从物品覆盖范围和排序满意度两个维度对模型进行优化,进一步增强了模型对尾部关系的敏感度,并提高了推荐精度。综上所述,本文的主要贡献包括:

(1) 本文提出了一种融合软硬策略的知识优化模块,通过挖掘知识图谱的深层语义,约束关系种类,从而缓解了长尾问题对推荐性能的影响。

(2) 本文提出了一种新颖的多视角损失函数,通过优化模型训练,提高了模型对尾部数据的关注度。

(3) 通过在两个公开数据集上进行了广泛的实验,从而证明了 DRMN 的有效性并强调了在知识图谱上缓解长尾问题的重要性。

1 相关工作

1.1 图神经网络

图神经网络通过其独有的消息传播机制,能够捕获用户交互图上的远距离依赖关系,从而提升推荐准确性。例如,GC-MC^[3]利用图卷积编码器来挖掘二部图中的潜在特征,并采用双线性解码器对评分进行类别化处理,从而预测评分等级。在面向大规模数据的推荐模型中,PinSAGE^[4]借鉴了GraphSAGE^[5]的核心理念,通过考虑邻近节点的影响来学习节点表示,从而有效提高了推荐效果。NGCF^[6]则定义了协作信号概念,并通过消息传递机制将其建模为高阶连接,从而提升了推荐性能。随后,LightGCN^[7]指出 NGCF 中的非线性激活函数与复杂特征转换属于冗余操作,并因此提出了一种简化的图神经网络模型,该模型在简化操作的同时,依然保持了优异的推荐性能。

1.2 基于知识图谱的推荐模型

现有基于知识图谱的推荐模型主要包括 3 种类型:基于嵌入的模型、基于路径的模型与基于传播的模型。基于嵌入的模型利用知识图谱嵌入模型,如 TransE^[8]和 TransH^[9],借助转换约束来学习用户与物品的表征。基于路径的模型^[10-12]依赖于知识图谱和交互图中的路径来连接用户与物品节点,进而解释用户与物品间的交互关系,并以此构建用户偏好模型。基于传播的模型则借助图神经网络将路径特征融入基于嵌入的模型,以实现更精准的推荐。RippleNet^[13]通过迭代扩展用户在知识图谱中的兴趣偏好,从而挖掘用户对物品的潜在兴趣。KGAT^[2]通过连续的卷积操作更新节点嵌入,完成

用户与物品之间的高阶连接建模。而 HAKG^[14] 则将节点嵌入映射至双曲空间,并设计了一种新型消息聚合机制,从而准确获取了用户与物品表征。尽管这些方法在推荐性能上取得了显著成果,但是现有方法忽略了知识图谱中关系的长尾分布特性,导致模型对部分关系过拟合,从而影响模型推荐精度。

2 问题定义

定义用户集合为 U , 物品集合为 I 。知识图谱 G_1 包含实体集合 E 和关系集合 R , 其中实体集合 E 是物品集合 I 的超集。在知识图谱 G_1 中,任意两个实体间的关系可以形式化地表示为三元组 (h, r, t) , 其中 $h, t \in E$ 分别代表头实体和尾实体, $r \in R$ 代表实体间的关系。本文所指的推荐任务是在给定用户交互图 G_0 和知识图谱 G_1 的情况下,构建一个

函数 $f(\cdot)$, 用于预测用户 u 与物品 i 之间的交互概率 \hat{y}_{ui} , 即 $\hat{y}_{ui} = f(u, i | G_0, G_1)$ 。

3 方法

3.1 知识优化

本节将详细介绍知识优化模块如何通过融合软硬策略缓解长尾效应。该模块旨在训练过程中对知识图谱语义进行深入挖掘,提供关系聚类约束以优化节点表征。为直观展示模型的整体流程,图 2 给出了模型的整体框架。首先,模块通过计算三元组得分,对部分知识进行遮蔽处理。随后,采用非监督学习方法对关系进行聚类,以构建聚类后的关系子图。最终,在模型优化阶段通过对遮蔽知识进行重建,以突出用户偏好的知识,知识重建步骤将在模型优化部分进行具体阐述。

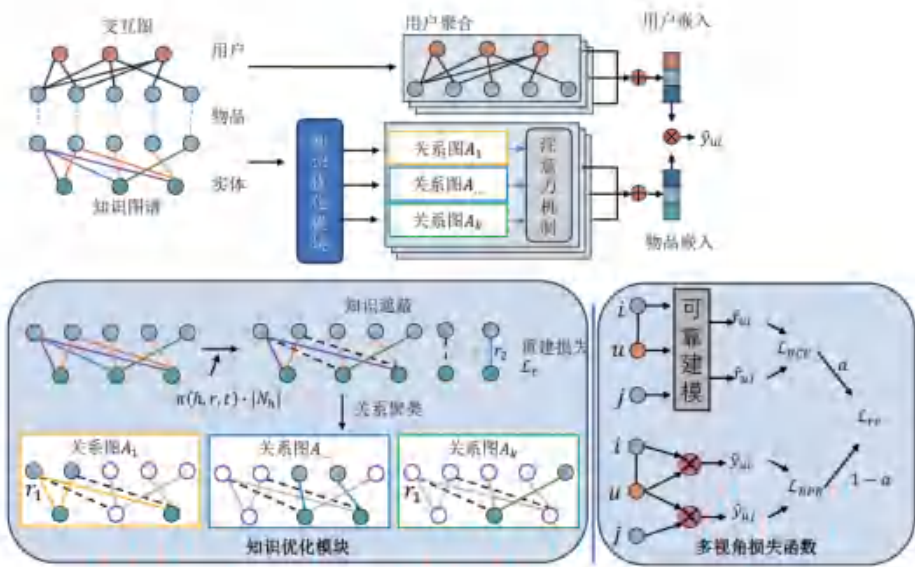


图 2 模型整体框架

Fig. 2 Overall framework of the model

3.1.1 知识遮蔽

目前,对掩码自编码器的研究^[15-16]揭示了其在数据重建过程中遮蔽关键信息,进而促进模型自动学习数据特征的潜力。基于这一发现,本文设计了一个自监督学习任务,通过遮蔽并重建知识图谱中的相关信息,迫使模型自主学习数据特征,并深入探索知识图谱的深层语义。

为了确保遮蔽的三元组能够促进模型对知识图谱深层语义的学习,本文设计了一种全局评估方法,以筛选知识图谱中的三元组。具体来说,本文首先获取特定三元组的局部重要性分数 $\pi(h, r, t)$, 当三元组连接越紧密时,该重要性分数越高:

$$f(h, r, t) = \frac{e_h \cdot (e_r \odot e_t)^T}{\sqrt{d}} \quad (1)$$

$$\pi(h, r, t) = \frac{\exp(f(h, r, t))}{\sum_{(h, r', t') \in N_h} \exp(f(h, r', t'))} \quad (2)$$

其中, e_h, e_r 和 e_t 分别表示头实体、关系以及尾实体的嵌入表征, N_h 表示头实体 h 的邻居三元组集合。

随后,利用头实体 h 的邻居数量 $|N_h|$ 来衡量头实体在整个知识图谱中的影响力。通过将局部权重与头实体重要性相结合,本文得到了一个能够反映特定三元组在整个知识图谱中全局重要性的评估方法:

$$\rho(h, r, t) = |N_h| \cdot \pi(h, r, t) = \frac{|N_h| \cdot \exp(f(h, r, t))}{\sum_{(h, r', t') \in N_h} \exp(f(h, r', t'))} \quad (3)$$

为了提高知识遮蔽策略的鲁棒性,本文向全局重要性分数 $\rho(h, r, t)$ 添加了 Gumbel 噪声,帮助模型更好地泛化到未见过的数据,提高模型在面对不同数据分布时的适应能力和鲁棒性。

$$\rho(h, r, t) = \rho(h, r, t) - \log(-\log(\epsilon)), \quad \epsilon \sim \text{Uniform}(0, 1) \quad (4)$$

其中, ϵ 是一个从均匀分布中抽样的随机变量。为了生成一组掩蔽知识三元组,本文选取前 k_m 个全局重要性分数较高的三元组来实现掩蔽:

$$M_k = \{(h, r, t) \mid \rho(h, r, t) \in \text{top } K(\Lambda; k_m)\} \quad (5)$$

其中, Λ 表示 $\rho(h, r, t)$ 的分布情况。为了构建一个标记为 G_m^a 的遮蔽知识图,本文从原始知识图 G_1 中删除了 $\rho(h, r, t)$ 得分较高的边 M_k 。具体而言,遮蔽知识图 G_m^a 是通过从知识图谱 G_1 中的边集中剔除边集 M_k 来实现的,即表示为 $G_1 \setminus M_k$ 。

3.1.2 关系聚类

在成功构建遮蔽知识图谱 G_m^a 后,本文通过关系聚类将剩余的关系类型约束为 K 个核心意图,以简化原始关系的复杂性,并有效缓解长尾分布问题,进而增强模型对三元组的理解能力。例如,“编剧”和“导演”等相似关系,可以通过相同的意图嵌入进行表征。这种聚类约束有助于将多样且分散的关系类型统一为更具代表性和信息性的分类,从而提升模型的推荐精度。

为了实现关系的有效聚类,本文提出了一种无监督学习算法,通过挖掘每个原始关系的潜在特征,将相似关系映射为同一意图向量。具体来说,初始化一个意图矩阵 $\mathbf{P} \in \mathbb{R}^{K \times d}$, 其中矩阵的第 k 行 \mathbf{p}_k 表示第 k 个意图向量的特征表示, K 为意图向量的总数。值得注意的是,这些意图向量被所有实体共享,即所有实体共用相同的意图空间。

$$\mathbf{P} = (\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_k)^T \quad (6)$$

为了从知识图谱中挖掘关系 $r_p \in R$ 的共性特征,并将其表达为意图向量,本文从意图矩阵 \mathbf{P} 中选择与关系 r_p 相似度最高的意图向量 \mathbf{p}_k 进行替换,从而更新知识图谱 G_m^a 。随后,根据意图向量的类型,将更新后的知识图谱划分为多个子图 A_k 。每个子图均通过相同的意图向量来连接其内部实体,从而保持了项目属性的语义独立性:

$$\mathbf{r}' = \text{argmax}_{k=1,2,\dots,K} (g(r_p, \mathbf{p}_1), \dots, g(r_p, \mathbf{p}_k), \dots) \quad (7)$$

其中, $g(\cdot)$ 代表相似度计算函数,具体实现为内积计算函数。

3.2 消息聚合

受 KGAT^[2] 等工作的启发,本文提出了一种新的知识聚合策略,用于在子图 A_k 上完成用户与物品的表示学习。该策略通过动态加权的方式将直接邻居信息编码至节点嵌入中,实现节点表示的更新,从而凸显不同邻居节点的重要性差异。

$$e_{N_h}^{(0)} = \frac{1}{\sqrt{|N_h|}} \sum_{t \in N_h} e_t^{(0)} \quad (8)$$

$$e_h^{(1)} = \frac{1}{\sqrt{|N_h|}} \sum_{t \in N_h} \omega(e_{N_h}, t) e_t^{(0)} \quad (9)$$

其中,尾实体 t 的 ID 嵌入为 $e_t^{(0)}$, $\omega(e_{N_h}, t)$ 为尾实体 t 在局部信息传播中的权重。该权重直观地反映了尾实体的信息交互强度,即当 $\omega(e_{N_h}, t)$ 得分较高时,尾实体 t 将提供更多的信息。本文通过计算实体 t 与局部信息表示 e_{N_h} 的相似性来确定权重值 $\omega(e_{N_h}, t)$, 并采用内积作为相似性度量方式,定义如下:

$$\omega(e_{N_h}, t) = e_{N_h}^{(0)T} \cdot e_t^{(0)} \quad (10)$$

随后,为了获取物品在特定方面的语义表征,本文在子图 A_k 上执行公式(9)的消息汇聚操作,获得特定子图上的嵌入表征 $e_{h,k}^{(1)}$ 。最后,采用注意力机制将不同方面的语义表征进行有效融合,从而得到物品的一阶表示 $e_h^{(1)}$, 融合过程如下式:

$$e_h^{(1)} = \sum_{k=0}^K w_k e_{h,k}^{(1)} \quad (11)$$

其中, w_k 表示从子图 A_k 上学习到的嵌入权重,用以衡量该意图向量在物品编码中的重要性。该权重在模型的训练过程中进行学习和调整,以确保能够有效反映各种意图向量对于最终物品表征的贡献程度,从而让模型聚焦于更具语义价值的子图信息。

为了捕捉用户和物品之间的协同信号,本文采用了一种类似于公式(9)的聚合策略来生成用户嵌入。该方法通过综合考虑用户与物品间的交互信息,从而实现对用户偏好的精准建模,进一步提升推荐模型的性能和用户满意度。

首先,计算用户历史交互物品的初始平均嵌入:

$$e_{Nu}^{(0)} = \frac{1}{\sqrt{|N_u|}} \sum_{i \in N_u} e_i^{(0)} \quad (12)$$

在此基础上引入动态权重完成交互信息的加权

聚合,得到用户的一阶嵌入表征:

$$e_u^{(1)} = \frac{1}{\sqrt{|N_u|}} \sum_{i \in N_u} \omega(e_{N_u}, i) e_i^{(0)} \quad (13)$$

其中, $e_i^{(0)}$ 表示物品 i 的 ID 嵌入; $e_u^{(1)}$ 表示一阶用户嵌入; N_u 表示用户 u 的历史交互物品集合。需要注意的是,在知识图谱中,物品 i 等同于某个头实体 h 或尾实体 t 。

3.3 模型预测

在经过 L 层的消息传递后,本文获得了用户 u 和物品 i 在不同层次上的表征,如公式(11)和公式(13)所示。在此基础上,本文通过聚合每一层的输出特征形成用户和物品的最终表征,并采用内积操作来估计用户 u 对物品 i 的评分,具体操作如下式:

$$\hat{y}_{ui} = e_u^{(*)T} e_i^{(*)} = \left(\sum_{l=0}^L e_u^{(l)} \right)^T \left(\sum_{l=0}^L e_i^{(l)} \right) \quad (14)$$

其中, \hat{y}_{ui} 为预测的用户 u 对物品 i 的偏好评分,其取值大小反映用户对物品的兴趣程度; $e_u^{(l)}$ 、 $e_i^{(l)}$ 分别表示用户 u 、物品 i 在第 l 层消息传递后的嵌入表征; L 为消息传递总层数。

3.4 模型优化

3.4.1 重建遮蔽连接边

为了重建被遮蔽的链接边 M_k , 本文设计了一种自监督学习策略。首先,在子图 A_k 上进行执行消息聚合操作,以生成实体的嵌入表示。其中,函数 $f_k(\cdot)$ 代表在知识图上的聚合函数,如下式:

$$e_h = f_k(A_k; h); e_t = f_k(A_k; t) \quad (15)$$

在聚合阶段,节点并不对 M_k 表示的知识三元组进行消息聚合,并且这些三元组将被作为重建过程中的自我监督标签。随后,本文采取最小化标签三元组的点积对数损失的策略来进行三元组重建,对应的损失函数如下式:

$$\mathcal{L}_c = \sum_{(h,r,t) \in M_k} -\log(\sigma(e_h^T \cdot (e_t \odot e_r))) \quad (16)$$

其中, $\sigma(\cdot)$ 表示 ReLU 激活函数。

3.4.2 多视角损失函数

本文对广泛应用的贝叶斯个性化排序 (Bayesian Personalized Ranking, BPR) 损失函数^[17]进行了改进,以优化模型对实体信息的利用效率。具体而言,本文在子图 A_k 上执行消息聚合操作,以生成物品嵌入表征。然后,为了进一步优化用户与物品嵌入,本文在 BPR 损失函数的基础上引入了一个二元交叉熵 (Binary Cross-Entropy, BCE) 损失函数。通过引入该函数使得模型能在训练过程中更好地区分不同类别,尤其是存在长尾分布的情况下也能较好地工

作。多视角联合损失函数的具体形式如下式所示:

$$\mathcal{L}_{\text{rec}} = \alpha \mathcal{L}_{\text{BCE}} + (1 - \alpha) \mathcal{L}_{\text{BPR}} \quad (17)$$

其中, α 用于控制 BCE 损失函数与 BPR 损失函数之间的相对重要性,其取值范围在 $[0, 1]$ 之间。值得注意的是,当 α 取值为 0 时,该损失函数将退化为纯粹的 BPR 损失函数。BCE 损失函数与 BPR 损失函数如下式所示:

$$\begin{aligned} \mathcal{L}_{\text{BPR}} &= \sum_{(u,i,j) \in \mathcal{O}} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (18) \\ \mathcal{L}_{\text{BCE}} &= - \sum_{(u,i) \in \mathcal{O}^+} \log(\sigma(\hat{r}_{ui})) - \sum_{(u,j) \in \mathcal{O}^-} \log(1 - \sigma(\hat{r}_{uj})) \quad (19) \end{aligned}$$

其中, $\mathcal{O} = \{(u, i, j) \mid (u, i) \in \mathcal{O}^+, (u, j) \in \mathcal{O}^-\}$ 表示训练数据集; \mathcal{O}^+ 表示用户历史交互; \mathcal{O}^- 表示未观察到交互的用户物品对; \hat{r}_{ui} 表示用户 u 与物品 i 的可靠性得分; 本文通过对用户与物品的表征进行点积操作,以获取其可靠得分。

3.4.3 整体损失函数

为了优化模型,本文使用了一种具有以下总体损失函数的联合学习方法:

$$\mathcal{L} = \mathcal{L}_{\text{rec}} + \lambda_1 \mathcal{L}_c \quad (20)$$

其中, λ_1 表示重建遮蔽知识任务在整体损失函数中的权重。为了保持表达的简洁性,本文省略了 $L2$ 正则化术语的符号。

4 实验

4.1 数据集

本文参照现有研究^[18]的数据处理方法,在 Last.FM (Last) 数据集和 MovieLens - 100K (ML - 100K) 数据集上进行实验验证。具体而言,对于 Last 数据集,本文利用 Microsoft Satori 知识图谱进行实体查询,并基于查询到的实体构建该数据集的知识图谱。而对于 ML - 100K 数据集,本文通过 Freebase 知识图谱获取相关实体信息,并仅保留置信度高于 0.9 的三元组,以确保所构建知识图谱的数据质量和可靠性。

4.2 评价指标和参数设置

在评估推荐模型性能时,本文在每个数据集上按照 8:2 的比例划分训练集与测试集。为了全面评估模型推荐性能,本文采用了两种广泛认可的评价指标:召回率 (Recall@K) 和归一化折损累计增益 (NDCG@K),并且设置 K 值为 5、10、20。

对于对比模型,本文根据原始论文提供的源代码进行模型复现。为了确保公平比较,嵌入的大小

被设定为 64,并依据原始论文调整了超参数。本文使用批量处理方式在训练和测试阶段进行数据处理,批大小设置为 4 096。本文采用 Adam 优化器对本文与对比模型进行优化。学习率的调整范围设为 $[1e-4, 1e-1]$, k_m 设置为 256,层数 L 的选择范围为 $\{2, 3, 4\}$,关系聚类数量设置为 $\{2, 3, 4\}$, α 选择范围为 $\{0, 0.1, 0.2, 0.4, 0.6, 0.8, 0.9, 1\}$ 。

4.3 对比模型

(1)FM^[19]:通过整合用户、物品以及实体的特征信息,分析特征间的二阶交互作用,从而有效挖掘用户与物品之间的潜在联系。

(2)NFM^[20]:一种在神经网络框架下对 FM 进行拓展的推荐模型,通过在输入特征层之上引入一个隐藏层,从而实现了 FM 与神经网络的深度融合。

(3)CKE^[21]:一种基于嵌入的推荐模型,利用

TransR 知识图谱嵌入模型来强化传统的矩阵分解方法,从而提高了推荐的准确性。

(4)KGAT^[22]:采用一种端到端的方式,对知识图谱中的高阶连接进行建模,并通过堆叠卷积层,实现了邻居嵌入的传播,从而优化了节点的特征学习。

(5)KGIN^[22]:利用知识图谱中的关系来解析用户的交互意图,并将这些意图嵌入到用户嵌入中,从而保留知识图谱中的高阶信息。

(6)VRKG^[18]:采用一种无监督学习策略对知识图谱进行分割。此外,该模型还设计了一种创新的消息聚合机制,使得能在分割后的子图上生成具有更高表现力和区分能力的表征嵌入。

4.4 实验结果

实验结果见表 1,其中最优结果使用粗体表示,次优结果使用下划线表示。

表 1 基于 Recall(R) 和 NDCG(N) 的对比实验结果

Table 1 Comparative experimental results based on Recall(R) and NDCG(N)

数据集	模型	R@ 5	N@ 5	R@ 10	N@ 10	R@ 20	N@ 20
Last	FM	0.053 3	0.046 7	0.088 3	0.060 7	0.140 2	0.077 2
	NFM	0.059 5	0.048 0	0.095 2	0.062 6	0.149 7	0.080 5
	CKE	0.130 6	0.112 6	0.188 5	0.136 2	0.269 5	0.162 5
	KGAT	0.078 6	0.094 9	0.125 6	0.125 8	0.205 9	0.167 1
	KGIN	0.174 2	0.152 4	0.249 6	0.183 2	0.354 9	0.216 9
	VRKG	<u>0.199 5</u>	<u>0.177 3</u>	<u>0.282 3</u>	<u>0.205 3</u>	<u>0.383 0</u>	<u>0.241 2</u>
	本文	0.208 2	0.183 9	0.291 4	0.210 4	0.389 5	0.249 2
	imp%	4.32	3.71	3.21	2.46	1.70	3.31
ML-100K	FM	0.114 3	0.267 4	0.189 3	0.252 4	0.309 5	0.281 7
	NFM	0.108 0	0.237 8	0.186 8	0.220 8	0.297 2	0.262 9
	CKE	0.142 5	0.287 4	0.224 7	0.289 0	0.328 0	0.309 1
	KGAT	0.093 6	0.269 1	0.154 9	0.280 8	0.248 4	0.289 1
	KGIN	<u>0.153 1</u>	0.273 5	0.156 8	0.266 1	0.262 5	0.273 1
	VRKG	0.149 6	<u>0.314 5</u>	<u>0.230 1</u>	<u>0.301 9</u>	<u>0.338 0</u>	<u>0.318 9</u>
	本文	0.155 2	0.321 3	0.234 8	0.309 8	0.347 5	0.326 8
	imp%	1.38	2.17	2.07	2.63	2.82	2.47

在两个公开数据集上,本文提出的 DRMN 明显优于 VRKG、KGIN 与 CKE 模型。这一结果充分证明了通过融合软硬策略来缓解知识图谱长尾问题的有效性。相比之下,FM 和 NFM 模型在两个数据集上的表现均不理想,这主要是因为 FM 模型难以充分利用知识图谱中的关系信息以提升物品表征质量。KGAT 模型性能表现相对较差,本文认为其原因在于知识图谱中关系的多样性导致 KGAT 模型在处理每种关系时,需要设定不同的注意力权重,从而

容易造成对关系的过拟合。对比 KGIN 与 CKE 的表现,本文发现在 Last 数据集上 KGIN 表现优于 CKE,而在 ML-100K 数据集上 CKE 表现优于 KGIN。通过分析两个数据集的差异,本文发现 ML-100K 数据集的知识图谱主要由一跳三元组组成,CKE 模型采用 TransR 进行知识图谱的语义转换,能够有效捕捉这种一跳连通性;而 KGIN 通过堆叠卷积层来挖掘高阶连通性时,则可能引入噪声信息,从而影响模型性能。而 VRKG 性能表现较差的原因

在于 VRKG 只使用了无监督方法进行知识图谱分割,并没有对知识图谱深层语义进行挖掘,因此性能弱于本文所提出的 DRMN。

4.5 重要参数对模型的影响

本文系统地设计了一系列实验,以证明 DRMN 模型的有效性。首先,本文对知识优化模块有效性进行了验证。其次,验证了模型多跳传播层数对推荐性能的影响,以此明确各核心模块与关键参数对模型推荐效果的作用机制。

4.5.1 知识优化模块对推荐性能的影响

本文通过调整关系聚类的数量来验证知识优化模块的有效性。此外,还设置了两个 DRMN 变体:一是将所有关系约束为单一类型,二是完全移除知识优化模块。在该实验中设定关系聚类 K 的取值范围为 $\{2,3,4\}$ 。实验结果如图 3 所示,其中 $K=1$ 代表所有关系被约束为单一类型, $K=|R|$ 则代表去除知识优化模块。

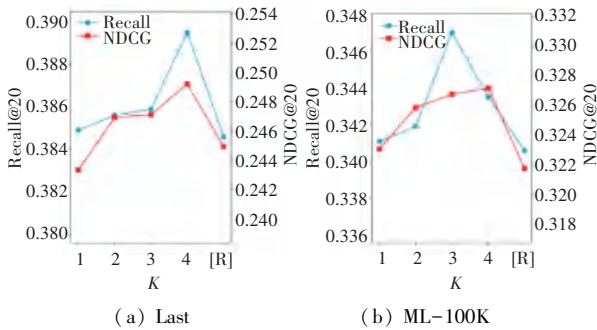


图 3 关系聚类 K 对性能影响

Fig. 3 Impact of relationship clustering K on performance

当 $K=1$ 与 $K=|R|$ 时,模型的性能表现均不理想,这有力地证明了本文提出的知识优化模块的重要性。本文将知识优化模块的有效性归因于以下两个方面:(1)当 $K=1$ 时,知识图谱中的所有关系都被转换为同一关系类型,这种过度的转换损害了关系的多样性,使得模型难以捕捉到用户的个性化需求。(2)当 $K=|R|$ 时,模型面临严重的长尾问题,并倾向于过度拟合头部关系,而忽略了对用户交互逻辑的深入挖掘,从而导致推荐性能较差。

值得注意的是,在 K 的取值范围为 $\{2,3,4\}$, $K=4$ 时,模型在两个数据集上取得了最优或次优推荐效果, $K=2$ 时表现最差。这一发现进一步证明了知识优化模块能够通过限制关系种类数量,缓解长尾效应,从而提升推荐性能。因此,调整超参数 K 是达到模型最优性能的关键步骤。

4.5.2 模型多跳传播层数对推荐性能的影响

本文深入探讨了节点表示学习过程中的消息聚

合机制对推荐性能的影响,并通过调整消息聚合层数 L 来有效地整合高阶节点信息,取值范围设置为 $\{1,2,3\}$,实验结果如图 4 所示。

实验结果显示,通过增加消息聚合层数,模型的性能得到了一定的提升。特别地,当聚合层数 L 设为 2 时,模型性能达到最优,这主要归因于模型能够通过堆叠更多聚合层来更深入地探索由三元组连接的其他物品,从而更全面地理解用户兴趣。然而,当进一步增加聚合层数 $L=3$ 时,模型性能出现了下降的趋势。这可能是因为在 $L=2$ 时,模型已经充分捕获了知识图谱中的关键信息,继续增加卷积层则会引入与推荐任务不相关的噪声信息,进而对模型的准确性造成干扰。因此,为了优化推荐模型的性能,需要对消息聚合层 L 进行精细调整。




图 4 传播层 L 对性能影响

Fig. 4 Impact of propagation layers L on performance

5 结束语

本文提出了一种基于多样关系建模的推荐模型 DRMN,该模型旨在通过解决长尾问题来提升推荐性能。首先通过深入挖掘知识图谱语义,使得模型能够深入理解用户与物品发生交互的潜在原因。其次提供关系聚类约束以优化节点表征,提升模型的表征能力。最后对损失函数进行改进,以进一步引导模型学习更准确的嵌入表征。为了验证 DRMN 模型的有效性,本文在两个公开的基准数据集上进行对比实验。实验结果表明,DRMN 在两个公开的基准数据集上的评价指标均优于现有模型。

由于本文所提出的模型侧重于用户偏好静态建模,该建模方式只在处理书籍推荐、电影推荐等用户偏好变化相对较少的场景时表现良好。为了应对用户偏好变化频繁的电商推荐,本文未来的工作计划将时序信息整合到知识图谱中,通过建模动态的用户偏好,实现更为灵活和精准动态推荐,从而能更全面的满足用户各方面需求。

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 World Wide Web Conference. 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. New York: ACM, 2019; 950–958.
- [3] VAN DEN BERG R, KIPF T N, WELING M. Graph convolutional matrix completion[J]. arXiv preprint arXiv, 1706.02263, 2017.
- [4] YING R, HE R, CHEN K, et al. Graph convolutional neural networks for web-scale recommender systems[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2018; 974–983.
- [5] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs[C]//Proceedings of the Advances in Neural Information Processing Systems. NeurIPS, 2017; 1024–1034.
- [6] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[J]. Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2019; 165–174.
- [7] 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. New York: ACM, 2020; 639–648.
- [8] BORDES A, USUNIER N, GARCÍA-DURÁN A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of Advances in Neural Information Processing Systems. NeurIPS, 2013; 2787–2795.
- [9] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes[C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2014; 1112–1119.
- [10] 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. New York: ACM, 2021; 1056–1064.
- [11] FAN S, ZHU J, HAN X, et al. Metapath-guided heterogeneous graph neural network for intent recommendation[C]//Proceedings of the 25th ACM SIGKDD International Conference On Knowledge Discovery and Data Mining. New York: ACM, 2019; 2478–2486.
- [12] HU B, SHI C, ZHAO W X, 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 and Data Mining. New York: ACM, 2018; 1531–1540.
- [13] 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. New York: ACM, 2018; 417–426.
- [14] DU Y, ZHU X, CHEN L, et al. HAKG: Hierarchy-aware knowledge gated network for recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022; 1390–1400.
- [15] HE K, CHEN X, XIE S, et al. Masked autoencoders are scalable vision learners[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2022; 16000–16009.
- [16] XIA L, HUANG C, HUANG C, et al. Automated self-supervised learning for recommendation[C]//Proceedings of the ACM Web Conference. New York: ACM, 2023; 992–1002.
- [17] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. UAL, 2009; 452–461.
- [18] LU L, WANG B, ZHANG Z, et al. VRKG4Rec: Virtual relational knowledge graph for recommendation[C]//Proceedings of the 16th ACM International Conference on Web Search and Data Mining. New York: ACM, 2023; 526–534.
- [19] RENDLE S, GANTNER Z, FREUDENTHALER C, et al. Fast context-aware recommendations with factorization machines[C]//Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2011; 635–644.
- [20] HE X, CHUA T S. Neural factorization machines for sparse predictive analytics[C]//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2017; 355–364.
- [21] 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. New York: ACM, 2016; 353–362.
- [22] WANG X, HUANG T, WANG D, et al. Learning intents behind interactions with knowledge graph for recommendation[C]//Proceedings of the ACM Web Conference. New York: ACM, 2021; 878–887.