

基于知识图谱的用户兴趣推荐^①

沈学利, 王嘉慧

(辽宁工程技术大学 软件学院, 葫芦岛 125105)

通信作者: 王嘉慧, E-mail: 2245414310@qq.com



摘要: 在提供精准的用户兴趣推荐时, 推荐系统的数据通常存在稀疏性问题, 对于新上线的项目存在冷启动问题, 缺乏用户交互数据, 为解决上述问题, 提出基于知识图谱的用户兴趣推荐算法. 首先, 在用户潜在兴趣中, 通过多层图神经网络根据用户和项目的嵌入向量, 获取用户和项目直接、间接和更深层次的关系, 解决数据稀疏性问题. 其次, 在用户显式兴趣中, 采用图结构增强根据评分权重随机删除用户和项目之间的显式关系, 通过编码器分析新的用户和项目节点的关系, 挖掘用户与项目间的交互关系, 解决冷启动问题. 最后, 采用特征交叉压缩单元结合知识图谱嵌入与推荐任务实现特征共享, 共享的特征更加深化项目与知识图谱实体间的互动, 提高推荐的准确性. 通过在 Book-Crossing 和 Last.FM 两个数据集上进行实验, 结果证明与其他对比算法相比在 AUC 和 ACC 评价指标中有显著的提升.

关键词: 推荐系统; 知识图谱; 图神经网络; 特征交叉压缩

引用格式: 沈学利, 王嘉慧. 基于知识图谱的用户兴趣推荐. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9850.html>

User Interest Recommendation Based on Knowledge Graph

SHEN Xue-Li, WANG Jia-Hui

(Software College, Liaoning Technical University, Huludao 125105, China)

Abstract: Data sparsity occurs in recommendation systems and the cold-start problem exists in newly launched items due to a lack of user interaction data when providing targeted user interest recommendations. To address these problems, this study proposes a user interest recommendation algorithm based on knowledge graphs. First, to tackle the data sparsity issue in users' potential interests, it employs a multi-layer graph neural network (GNN) to capture the direct, indirect, and deeper relationships between users and items through their embedding vectors. Second, for users' explicit interests, it introduces a graph structure enhancement technique to randomly delete explicit relationships between users and items based on rating weights. This method leverages an encoder to analyze the relationships of new users and item nodes, uncovering interactive relationships between users and items, thereby addressing the cold-start problem. Finally, a feature cross-compression module is used to combine knowledge graph embeddings with the recommendation task to achieve feature sharing. The shared features further deepen the interaction between items and knowledge graph entities, enhancing recommendation accuracy. Experiments conducted on the Book-Crossing and Last.FM datasets demonstrate that the proposed algorithm significantly outperforms other baseline algorithms in terms of AUC and ACC indicators.

Key words: recommendation system; knowledge graph; graph neural network (GNN); feature cross-compression

^① 基金项目: 国家自然科学基金面上项目 (42271409)

收稿时间: 2024-09-16; 修改时间: 2024-10-30, 2024-11-29; 采用时间: 2024-12-11; csa 在线出版时间: 2025-03-04

信息时代的到来促使网络资源呈指数级增长,导致在线信息资源严重过载,这一现象已深刻渗透到人们的日常生活中^[1]。然而,面对海量信息,用户的兴趣需求日益增长,如何在这些信息中找到并推荐符合用户兴趣的项目成为亟待解决的问题。因此,基于用户兴趣的推荐方法具有重要的意义和价值。

深度学习与推荐系统的结合已经成为一个活跃的研究领域,许多新模型不断涌现^[2]。然而这些模型主要聚焦于用户行为特征间的高阶交互,导致生成的向量化表示精度较低。在用户与项目交互稀疏的场景中,模型能够提取的信息有限。从机器学习初期到深度学习的今天,推荐精度不断提高^[3],但存在数据稀疏和冷启动问题^[4],常见的解决方案是引入额外辅助信息与利用邻近性^[5,6]和其他类型的关系合并到推荐模型中。自2012年Google推出首版知识图谱以来,知识图谱迅速引发了学术界和工业界的广泛关注^[7]。知识图谱是一种多关系网络,其中节点表示现实世界的实体,边表示实体间的关系,每两个节点与一条边构成一个知识三元组<head, relation, tail>^[8]。在推荐系统中,为解决用户-项目交互存在冷启动的问题,利用用户-项目二分图^[9,10],通过二阶邻近性提取用户和项目的特征向量,结合知识图谱中的实体信息进行节点表示学习,从而提升推荐效果。

将知识图谱与推荐系统相结合,可以有效补充项目的信息提升模型性能。然而现有基于知识图谱的推荐模型中,用户和项目的向量表示不够准确,且由于用户与项目交互有限存在数据稀疏和冷启动问题,未能充分挖掘知识图谱中的信息,这限制了模型性能的进一步提升。为此,本文提出基于知识图谱的用户兴趣推荐算法,其核心思路包括以下内容。

(1) 通过依据评分权重随机删除同时结合GCN编码器的高效图结构增强能力,捕获用户显式兴趣,缓解冷启动问题。

(2) 为了丰富用户和实体之间的关系,构建用户-项目-实体图,并使用逐层图神经网络(Tri-GNN)模块探索图结构数据中的语义关系,获得用户潜在兴趣,缓解数据稀疏性问题,进一步提高推荐效果。

(3) 在知识图谱嵌入模块中,通过捕捉头实体和关系之间的高阶特征关联预测尾实体,并增加尾实体额外信息流表示,提升预测性能。

1 相关工作

1.1 知识图谱

知识图谱具有强大的语义表达能力,本质上是语义网络的知识库。谷歌于2012年提出知识图概念,旨在利用知识库来提高搜索引擎的性能,增强用户的搜索效率^[9]。随着人工智能的发展和应用,知识图谱已广泛应用于智能搜索、智能问答和个性化推荐等领域^[10]。知识图谱已被构建并广泛应用于多种场景,基于嵌入的方法^[11]通过知识图谱嵌入(KGE)表征实体和关系,获取额外的语义信息。基于路径的方法^[12]聚焦于用户和项目对,利用从知识图谱中提取的路径来预测用户偏好,但是面对大规模图结构数据时路径提取挑战增大。当前,基于知识图谱的推荐系统已取得不错的效果。知识图谱特征学习在推荐系统中的应用主要通过顺序学习、联合学习和多任务学习3种方法,典型的分别是DKN^[13]、CKE^[14]和MKR^[15]模型。本文使用多任务学习策略进行建模。DKN^[13]模型将知识图谱应用于新闻推荐领域,为实体学习到嵌入向量,并结合其上下文将嵌入作为新闻特征表示。但在其训练过程中,将知识图谱和推荐系统看作是分离的模块,使得模型无法直接挖掘项目和实体之间的联系。而MKR^[15]模型在一定程度上解决了这一问题,该模型通过交替学习的方式,采用多任务框架,它将知识图谱学习任务与推荐任务很好地结合起来进行训练,从而提高最终推荐的性能。

1.2 图神经网络

图神经网络(graph neural network, GNN)在将神经网络应用于非欧几里得数据空间进行特征学习方面取得了显著进展^[16]。2009年,Scarselli等人^[17]首次提出GNN的概念,奠定了这一领域的基础。然而,2017年,Kipf等人^[18]提出了图卷积神经网络(graph convolutional neural network, GCN)模型,极大地推动了图神经网络的快速发展。

由于其强大的特征聚合与高阶连接建模能力,GCN技术在推荐系统中引起了越来越多的关注^[19,20]。Wang等人^[6]提出的NGCF模型首次将GCN引入推荐算法,能够建模用户与物品之间的高阶连接,但是未考虑边的重要性。Chen等人^[21]提出的NIA-GCN模型在GCN框架的基础上进一步发展,考虑邻近节点之间的相互作用。该方法通过聚合不同深度的邻居节点信息,生成更全面的节点表示。为进一步提升模型的鲁棒性和泛化能力,近年来的研究引入基于评分权重的随机删除

技术. Chen 等人^[22]提出的 DropEdge 模型通过随机删除部分边,减轻过拟合问题并增强模型的泛化能力. 该方法通过动态采样和随机删除边,保留对推荐任务贡献较大的边,从而减少低权重边的干扰,提高推荐系统对冷启动问题的适应性. Connelly 等人^[23]提出的 GCN-ONCF 模型使用 GCN 作为编码器,并通过外积操作将编码向量转化为二维特征矩阵. 该模型利用卷积自动编码器实现了卷积矩阵分解,为推荐任务提供了高效的解决方案. 本文创新性地结合评分权重随机删除和 GCN 聚合,形成了更精细的特征建模机制,有效缓解冷启动问题.

为充分挖掘知识图谱中的信息并缓解数据稀疏性问题,本文将用户-项目交互图与知识图谱结合,构建了用户-项目-实体图,并通过图神经网络(GNN)增强知识图谱节点的表示,从而提高推荐效果. 典型方法如 KGAT^[25]和 KGIN^[25],这两种方法基于图神经网络,通过消息传递机制对用户、项目及知识图谱中的实体信息进行特征聚合,学习节点的高维表示. 然而 KGAT 和 KGIN 通常采用较浅的网络结构,难以有效捕获图中复杂的深层次高阶关系. 为改善这一问题,张俊三等人^[26]设计了基于 GNN 的邻域采样策略,以用户为中心构建子图,并将次高阶项目(即三阶邻居)作为负样本,提升了模型区分正负样本的能力. 然而,该方法在处理稀疏数据时存在一定限制,因为高阶项目的质量和数量直接影响负样本的有效性. 另外,杨智伟等人^[27]引入自适应矩估计优化器(Adam),并通过多层卷积聚合不同层次的邻域信息,从而生成更为精细的用户和项目表示. 尽管如此,多层卷积与 Adam 优化器的结合引入多个超参数,这些超参数的设置可能影响模型的训练效果. 李鹏飞等人^[28]采用 R-GCN 从异构网络图中提取节点的全局特征,能够捕捉用户与兴趣之间的复杂关系,从而更全面地理解用户的整体偏好. 但该方法对异构图的特征选择和节点类型依赖性较强,影响推荐准确性. 本文提出的多层图神经网络模型,通过在不同层次逐步聚合用户和项目节点的邻域信息,从局部兴趣到全局特征逐层建模,能够更精细地表达用户和项目的偏好,充分利用稀疏数据中的隐含关联,进而有效缓解数据稀疏性问题.

2 基于知识图谱的用户兴趣推荐算法

用户的兴趣通过点击、购买、评分和浏览等交互

行为来体现. 对于新注册用户和新上线项目,缺乏足够的交互数据,导致数据稀疏和冷启动问题,从而难以准确评估用户兴趣. 为更好地解决上述问题,提出基于知识图谱的用户兴趣推荐算法(KGMG),该算法由推荐模块和知识图谱嵌入模块构成,两个模块通过特征交叉压缩单元(T)完成特征共享^[15],KGMG 模型结构如图 1 所示,在推荐模块中的用户潜在兴趣建模中,使用多层图卷积(Tri-GNN)逐层聚合其直接邻居的嵌入向量来计算用户和项目直接、间接和更深层次的关系,最终用户和项目每层的嵌入通过加权和函数来获得,表示为 P_u 和 P_v ;在用户显式兴趣建模中,使用图结构增强(GA),依据用户对项目的评分,将评分作为权重随机删除低权重边,通过编码器聚合分析用户和项目节点的邻居关系获得显式用户和项目的特征 G_u 和 G_v ;用户潜在兴趣生成的用户和项目特征与用户显式兴趣生成的用户和项目特征进行加权和,最终通过多层感知器(MLP)用内积来表示用户和项目之间的交互概率,预测潜在用户和显式用户对项目的兴趣度,获得 \hat{Y}_{uv} ,该预测值决定是否向用户推荐候选项目. 知识图谱嵌入模块通过相似性函数 *similarity* 计算三元组 $\langle h, r, t \rangle$ 最大相似性,结果越大越相似. 特征交叉压缩单元将显式项目特征 G_v 和头实体(h)进行交互,获得组合特征,通过权重向量将交叉特征矩阵从较高维空间压缩回原始特征空间,使得模型能够在多个任务之间共享有用的特征,最终得到一个能够预测评分的函数 $\mathcal{F}(u, v | \Theta, Y, \mathcal{G})$.

2.1 问题公式化

本文中使用的关键符号,并将研究任务形式化. 在这个标准的推荐系统场景中,定义了用户集 $U = \{u_1, u_2, \dots, u_M\}$ 和项目集 $V = \{v_1, v_2, \dots, v_N\}$,单个用户和项目分别表示为 u ($u \in U$)和 v ($v \in V$).

知识图谱模块: 图 1 右侧知识图谱嵌入模块 $\mathcal{G} = \langle h, r, t \rangle$ 表示知识图谱,描述头实体(h)与尾部实体(t)之间的语义关联,其中 r 是它们之间的交互关系(用户与项目的点击、购买、评分、浏览等复杂关系行为)通过不同类型的实体和它们之间的关系来组织外部项目属性.

推荐模块: 定义用户-项目交互矩阵 $\mathcal{Y} \in Y^{M \times N}$ 代表用户对不同项目的偏好行为, M 、 N 分别表示用户和项目的数量, $\mathcal{Y}_{uv} = 1$ 的表示用户与项目有交互; $\mathcal{Y}_{uv} = 0$ 表示用户没有参与项目.

任务制定: 给定用户-项目交互矩阵 Y 以及知识图谱 \mathcal{G} , 预测用户 u 是否项目 v 具有兴趣. 目标是学习一个预测函数 $\hat{Y}_{uv} = \mathcal{F}(u, v | \Theta, Y, \mathcal{G})$, 其中 \hat{Y}_{uv} 表示用户 u 将

与项目 v 互动的概率, 并且 Θ 是函数 \mathcal{F} 的模型参数. 通过公式化设定可以整合传统推荐系统和知识图谱的优势, 提升推荐的准确性和系统的解释能力.




图 1 KGMG 算法整体框架

2.2 图结构增强进行用户显式兴趣建模

在推荐模块输入中, 直接使用用户-项目图作为输入, 推荐结果会倾向于用户已有行为的相似项目, 导致推荐的多样性不足. 通过图结构增强聚合邻居节点的特征, 提取用户-项目之间的显式关系特征作为其显式兴趣表示. 对于新用户或新项目, 利用已有的相似用户-项目节点和边(关系)的信息进行推荐, 快速为新用户或项目建立有效的推荐, 以解决冷启动问题. 将用户对项目的评分作为权重, 根据权重值进行随机删除, 生成两个增强视图 \mathcal{G}_u 和 \mathcal{G}_v . 图结构增强模块如图 1 中 GA 所示, 其中橘色虚线部分表示随机删除的用户关系, 蓝色表示随机删除的项目关系, 删除低权重边, 因为低权重边代表低频次的互动, 保留高权重边, 可以使

用户和项目之间的多样性关系得到更好的维护, 打破图结构中的过度依赖关系, 有效解决显式用户兴趣推荐过程中冷启动问题, 防止算法过拟合, 提高算法的泛化能力.

将两个增强视图可用数据公式化为用户-项目二分图 $G = \{U \cup V, B\}$, $U \cup V$ 表示节点集合, 如式 (1) 所示:

$$B = \begin{bmatrix} 0^{M \times M} & \mathcal{Y} \\ \mathcal{Y}^T & 0^{N \times N} \end{bmatrix} \quad (1)$$

其中, B 表示邻接矩阵, 包含用户和项目的交互信息, \mathcal{Y} 表示用户-项目进行交互矩阵, $0^{M \times M}$ 、 $0^{N \times N}$ 分别表示用户、项目没有进行交互, \mathcal{Y}^T 表示用户-项目进行交互矩阵的转置矩阵. 随后利用 GCN 编码器捕获邻接矩

阵 B 中的直接邻居信息以获取用户显式兴趣, 更新节点嵌入, 该过程如下:

$$G^l = D^{\frac{1}{2}} B D^{-\frac{1}{2}} G^{l-1} \quad (2)$$

其中, 给定初始化的节点嵌入 G^0 , G^l 和 G^{l-1} 分别表示在图卷积层中的节点嵌入 l 层和 $l-1$ 层, G^l 是第 l 层的节点特征矩阵, 包含用户和项目的特征, D 是满意度矩阵, G^{l-1} 是第 $l-1$ 层的权重矩阵. 当堆叠卷积层时, 可以通过式 (3) 读出操作获得最终的节点表示.

$$G = \text{Readout}(G^0, G^1, \dots, G^l) \quad (3)$$

最后 GCN 编码器利用所得最终的节点, 聚合分析用户和项目节点的邻居关系, 以生成用户和项目特征为 G_u 和 G_v , 揭示用户显式兴趣偏好.

$$G_u = \varepsilon(G_u, G^0), \quad G_v = \varepsilon(G_v, G^0) \quad (4)$$

其中, $\varepsilon(\cdot)$ 表示 GCN 编码器, G_v 用于与特征交叉压缩单元的项目输入, 输出项目 V_{out} 表示如下:

$$V_{\text{out}} = T(G_v, h)[G_v] \quad (5)$$

其中, V_{out} 表示图结构增强模块输出的用户特征向量, $[G_v]$ 表示显式用户兴趣项目特征矩阵. T 表示特征交叉压缩操作, 本文所提算法使用一个 T , 可以显著减少计算和内存需求, 使得模型在处理大规模数据时更加高效.

2.3 多层神经网络进行用户潜在兴趣建模

在用户潜在兴趣建模过程中, 用户或项目交互数据往往很稀疏. 引入实体之后, 可以通过共享的实体信息和关系, 增强推荐系统的推理能力, 缓解数据稀疏性问题. 由于 Light-GCN^[29] 的有效性和轻便性, 在效率方面取得优异的表现, 本文借鉴其设计理念, 构建 Tri-GNN 模块, 如图 1 中 Tri-GNN 所示. 相较于 Light-GCN, Tri-GNN 通过层叠多层卷积不仅能够捕捉更深层次的图结构信息, 提升嵌入的表达力, 同时能够更精准细致地控制信息传播的深度和范围, 有效减少过度平滑问题, 使得每一节点能够保留其特有的特征信息.

Tri-GNN 能够根据用户和项目的嵌入向量, 综合考虑用户和项目直接、间接和更深层次的关系, 预测潜在用户兴趣, 预测过程如下:

$$e_v^{(l+1)} = \sum_{v \in \mathcal{N}_v} \frac{1}{\sqrt{|\mathcal{N}_u| |\mathcal{N}_v|}} e_v^{(l)} \quad (6)$$

$$e_u^{(l+1)} = \sum_{u \in \mathcal{N}_v} \frac{1}{\sqrt{|\mathcal{N}_u| |\mathcal{N}_v|}} e_u^{(l)} \quad (7)$$

其中, $e_u^{(l)}$ 和 $e_v^{(l)}$ 分别表示用户 u 和项目 v 的第 l 层嵌入,

l 为 GNN 卷积层数, \mathcal{N}_u 表示与用户 u 交互的项目集合, \mathcal{N}_v 表示与项目 v 交互的用户集合. 对称正则化项 $\frac{1}{\sqrt{|\mathcal{N}_u| |\mathcal{N}_v|}}$ 遵循标准 GCN 结构, 避免嵌入的大小随着图卷积运算而增加. 在传播到 l 层之后, 加权和函数被用作聚合函数组合每层的嵌入以获得最终表示, 如式 (8) 和式 (9) 所示.

$$P_u = \frac{1}{l+1} \sum_{l=0}^l e_u^{(l)} \quad (8)$$

$$P_v = \frac{1}{l+1} \sum_{l=0}^l e_v^{(l)} \quad (9)$$

其中, P_u 和 P_v 分别是用户 u 和项目 v 的加权和函数表示. 而后将 P_v 与图结构增强产生的 V_{out} 加和运算拼接得到最终项目向量, P_u 经过图结构增强产生的 G_u 加和运算拼接得到最终用户向量, 最后通过 MLP 将最终的用户和项目特征向量拼接在一起进行点击率预测 \hat{Y}_{uv} , 如式 (10) 所示.

$$\hat{Y}_{uv} = \text{MLP}((G_u \oplus P_u)^T \otimes (V_{\text{out}} \oplus P_v)) \quad (10)$$

其中, \hat{Y}_{uv} 是用户 u 和项目 v 之间的交互的预测得分, 其被用作推荐生成的排名.

2.4 知识图谱嵌入模块

知识图谱嵌入用于计算实体间的相似性, 通过相似性比较预测用户偏好的项目与实际感兴趣的项目, 从而提升匹配的准确性, 如图 1 中知识图谱嵌入模块所示. 对于给定知识图谱三元组 (h, r, t) , 其中 h 、 r 、 t 分别表示头实体、关系实体和尾实体. 头实体通过特征交叉操作 (T) 获取头实体特征向量 h_l , 计算过程如式 (11) 所示:

$$h_l = T(G_v, h)[h] \quad (11)$$

其中, G_v 是推荐模块的项目的输入, $[h]$ 是头实体矩阵.

由于关系实体通常是高维的向量或张量, CNN 提取关系实体有效地对其降维、压缩, 保留关键特征, 去除冗余信息. 关系实体使用卷积神经网络 (CNN) 获得关系实体特征向量 r' , 同时使用 CNN 提取尾实体特征有效加强知识图谱嵌入模块的信息完整性. 计算过程如下所示:

$$r' = C(r) \quad (12)$$

$$t' = C(t) \quad (13)$$

其中, C 表示卷积神经网络 CNN. CNN 提取的关系实

体特征 r' 与经过特征交叉压缩提取的头系实体特征 h_l 通过多层感知器 (MLP) 得到预测尾部 \hat{t} , 提高尾实体预测的准确性, 计算过程如下所示:

$$\hat{t} = MLP(h_l \otimes r') \quad (14)$$

其中, \otimes 表示点乘操作, MLP 是多层感知机. 最终预测尾实体与目标尾实体的相似性通过相似性函数进行评估, 计算过程如下:

$$similarity(t', \hat{t}) = f_{KG}(t', \hat{t}) = -\sigma(t'^T \hat{t}) \quad (15)$$

其中, σ 表示 Sigmoid 激活函数, 采用标准化内积的方法来计算相似度, 若相似度高就会进行推荐, 相反则会丢弃.

2.5 损失函数及算法表示

算法的损失函数如下:

$$\begin{aligned} \mathcal{L}_{\text{总}} = \mathcal{L}_{\text{RS}} + \mathcal{L}_{\text{KG}} + \mathcal{L}_{\text{REG}} = & \sum_{u \in U, v \in V} \mathcal{F}(\hat{y}_{uv} - y_{uv}) \\ & + \sum_{(h,r,t) \in \mathcal{G}} similarity(t', \hat{t}) + \lambda \|W\|_2^2 \end{aligned} \quad (16)$$

其中, \mathcal{L}_{RS} 是推荐模块的损失值, \mathcal{L}_{KG} 是知识图谱嵌入模块的损失值, 其中 \mathcal{F} 是交叉熵损失函数, \mathcal{L}_{REG} 是正则化项, 防止过拟合, λ 是正则化项系数.

3 实验分析

3.1 数据集

为评估算法的有效性, 本实验使用两个由亚马逊公司提供的公共数据集 Book-Crossing^[30] 和 Last.FM^[31].

Book-Crossing: Book-Crossing 数据集包含超过 100 万个显示的书籍评分的数据集, 范围为 1-10.

Last.FM: 该用户偏好数据集来自在线音乐服务, 该数据集中包含每个用户的顶级艺术家和播放次数.

由于上述两个数据集都是显式反馈数据集, 根据 RippleNet^[29] 将其转化为隐式反馈, 由于 Book-Crossing 和 Last.FM 数据的稀疏性, 这些数据未设置正向评分阈值. 在用户-项目-实体的构建中使用 Microsoft Satori, 并选取置信度高于 0.9 的三元组作为所构建知识图谱的子集. 对于所构建知识图谱, 通过比较数据集名称与三元组的头实体名称, 筛选出匹配良好的三元组. 表 1 展示了这两个数据集的基本统计信息.

3.2 评价指标、参数设置

3.2.1 评价指标

在验证算法阶段, 实施全面的排名策略, 具体如下:

对用户未互动的所有项目均视为负样本, 对用户互动的所有项目均视为正样本. 采用 ROC 曲线下方面积大小 (area under curve, AUC) 和准确率 (accuracy, ACC) 作为 CTR (click through rate) 预测实验的评估指标, 在推荐系统中, 正负样本比例通常不平衡, 即用户有限的交互行为导致正例 (用户感兴趣的项目) 较少, AUC 对于不平衡数据集具有较好的鲁棒性, 能够有效地评估算法在各类别上的分类性能.

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} \quad (17)$$

$$precision = \frac{TP}{TP + FP} \quad (18)$$

$$recall = \frac{TP}{TP + FN} \quad (19)$$

$$FPR = \frac{FP}{N} \quad (20)$$

$$TPR = \frac{FP}{P} \quad (21)$$

其中, 预测率 (precision) 代表预测的 K 个项目中预测正确的比例, 反映推荐的查准率, 式 (19) 召回率 (recall) 表示样本中的正例有多少被预测正确, 反映推荐的查全率. TP (true positive): 被算法正确预测为正类的样本数, 即用户实际喜欢的项目被正确推荐给用户的数量. TN (true negative): 被算法正确预测为负类的样本数, 即用户实际不喜欢的项目没有被推荐给用户的数量. FP (false positive): 被算法错误预测为正类的样本数, 即用户实际不喜欢的项目被错误推荐给用户的数量. FN (false negative): 被算法错误预测为负类的样本数, 即用户实际喜欢的项目没有被推荐给用户的数量. AUC 值介于 0 和 1 之间, 越接近 1 表示模型性能越好. 假阳率 (false positive rate, FPR): 表示 ROC 曲线的横坐标, 真阳率 (true positive rate, TPR): 表示 ROC 曲线的纵坐标, AUC 的值是对 ROC 曲线的横轴做积分.

表 1 数据集统计数据

数据集	Book-Crossing	Last.FM
用户-项目交互	用户数量	17390
	项目数量	143610
	交互数量	138612
知识图谱	三元组数量	19680
稀疏率 (%)		99.99

3.2.2 参数设置

为评估在不同数据集上的性能, 设定的实验配置

如下:每个数据集内的用户交互记录被随机划分为训练集、验证集和测试集,比例为7:1:2。训练集用于算法训练,验证集用来调整超参数,测试集用于评估最终算法性能。使用PyTorch的Python库来实现算法,采用Adam优化算法,设置正则化系数(λ)设为 10^{-5} ,嵌入维度 d 设置{8,32,64,128},学习率为{ 10^{-6} , 10^{-5} , 10^{-4} , 10^{-3} , 10^{-2} }。

3.3 对比算法

为了验证KGMG算法的有效性,在CTR预测场景和Top-K推荐场景下都做了相关实验,将其与近两年最新算法(KMRH、DEKGCL、KGNN-LS、ECFKG)和主流算法(MKR、KGAT、KGIN、CKAN、BPRFM)进行比较。

MKR^[15]:是基于多任务学习的推荐算法,通过特征交叉压缩共享推荐模块和知识图谱模块,有效地结合用户项匹配和知识图嵌入任务。

KGAT^[24]:是基于知识图谱的算法,算法利用注意力机制在知识图谱中构建高阶关系。

KGIN^[25]:是通过知识图谱来揭示用户-项目交互的意图粒度,增强不同意图的独立性,考虑更细粒度的用户-项目关系及关系路径的远程语义。

KGNN-LS^[32]:将知识图谱和标签平滑结合,通过引入标签平滑正则化作为正则化项来有效防止过拟合。

ECFKG^[33]:构建了一个用户-项目知识图,用户、项目及其相关属性被视为实体,用户的历史行为(如购买和提及)被视为实体之间的一种关系。

CKAN^[34]:建立在KGNN-LS的基础上,分别在协同过滤和知识图谱上使用独立的协作传播和知识信号,使用异构传播策略对两种类型的信息进行编码,并应用知识感知注意力机制来区分不同知识邻居的贡献。

BPRFM^[35]:利用BPR的排序优化目标和FM的特征交互建模能力,用于处理大规模推荐任务中的隐式反馈数据。

DEKGCL^[36]:通过对用户-项目图双端建模的方法增强图结构,对用户的嵌入整合来自不同项目节点的信息,使得用户的表示不仅基于其直接行为,还包含与其他用户或项目的协同信息。

KMRH^[37]:利用双曲几何的指数扩展特性,使用多任务学习方法捕捉图结构中的高阶关系,对潜在用户进行建模。

在表2和表3中显示KGMG算法在两个真实数

据集上的CTR(点击率)预测实验和Top-K实验的结果。在稀疏的Book-Crossing数据集的点击率(CTR)任务,本文所提算法KGMG相较于原模型MKR在AUC和ACC指标上分别提升3.3%和2.4%;Last.FM数据集KGMG算法相较于原模型MKR在AUC和ACC指标上分别提升1.8%和2.6%。从实验结果可以看出KGMG算法在CTR预测上优于传统的推荐算法,对Book-Crossing数据集从不同对比模型的方法分析,较以知识图谱为依据的传统模型KGIN和KGAT,本文所提KGMG算法在AUC和ACC指标分别提升2.0%、2.4%和2.8%、4.5%,较近年流行模型ECFKG,KGMG在AUC和ACC指标分别提升6.8%和1.9%,表明本文模型通过知识图谱嵌入,能够有效地丰富关系信息,提高推荐的准确性。对比依赖邻居节点的KGNN-LS模型,KGMG在AUC和ACC指标分别提升8.0%和7.9%,说明KGMG使用Tri-GNN逐层获取图中邻居节点的嵌入表示,有效解决用户兴趣的数据稀疏性问题。较依据高阶特征交互的BPRFM模型,KGMG在AUC和ACC指标分别提升9.0%和3.9%;较基于双曲空间特征交互的KMRH模型,KGMG在AUC和ACC指标分别提升3.9%和2.0%,说明KGMG采用单次特征交叉压缩可以更好地取特征交互信息并进行特征共享。对比使用信息编码进行图结增强的CKAN模型,KGMG在AUC和ACC指标分别提升1.4%和6.8%,对比使用双端建模的方法完成增强图结构的DEKGCL模型,KGMG在AUC和ACC指标分别提升1.8%和2.9%,证明使用随机删除的图结构增强,可以使用户和项目之间的多样性关系得到更好的维护,有效解决冷启动问题。为进一步验证算法泛化能力,本文在Last.FM数据集上述算法进行对比实验,结果如表3所示。结果表明,本文算法在各评价指标上均表现出优异的性能,具有较强的泛化性与鲁棒性。

在Top-K(为用户推荐的前K个最相关或最优的物品)预测中,针对Book-Crossing数据集,预测率和召回率均高于其他对比模型,在 $K=20$ 时,提升效果最佳。当 $K=20$ 时,KGMG算法预测率较近年最新模型KMRH提升1.4%,较DEKGCL模型提升1.7%,较原模型MKR提升1.1%。KGMG算法召回率较近年最新模型KMRH提升2.9%,较DEKGCL模型提升3.4%,较原模型MKR提升7.3%。表明KGMG算法有效缓解数据稀疏性和冷启动问题。

表 2 不同模型之间的性能比较 (Book-Crossing)

算法	AUC	ACC	Precision@K					Recall@K				
			5	10	20	50	100	5	10	20	50	100
ECFKG	0.695	0.698	0.034	0.030	0.017	0.012	0.004	0.048	0.059	0.079	0.081	0.086
KGAT	0.735	0.672	0.019	0.011	0.007	0.006	0.005	0.022	0.032	0.040	0.064	0.096
BPRFM	0.673	0.678	0.020	0.014	0.010	0.004	0.009	0.037	0.043	0.065	0.084	0.093
KGNN-LS	0.683	0.638	0.035	0.028	0.024	0.019	0.017	0.026	0.045	0.075	0.096	0.159
KGIN	0.743	0.693	0.036	0.027	0.023	0.018	0.017	0.038	0.047	0.071	0.093	0.138
CKAN	0.749	0.649	0.038	0.030	0.027	0.025	0.013	0.045	0.056	0.079	0.115	0.147
MKR	0.730	0.693	0.024	0.021	0.018	0.014	0.010	0.048	0.059	0.065	0.086	0.131
KMRH	0.724	0.697	0.038	0.035	0.015	0.013	0.015	0.053	0.094	0.109	0.121	0.142
DEKGCL	0.745	0.688	0.035	0.029	0.012	0.014	0.012	0.058	0.092	0.104	0.125	0.145
KGMG	0.763	0.717	0.039	0.031	0.029	0.027	0.019	0.065	0.097	0.138	0.171	0.192

表 3 不同模型之间的性能比较 (Last.FM)

算法	AUC	ACC	Precision@K					Recall@K				
			5	10	20	50	100	5	10	20	50	100
ECFKG	0.703	0.705	0.029	0.025	0.012	0.009	0.007	0.013	0.016	0.021	0.037	0.042
KGAT	0.786	0.662	0.036	0.025	0.014	0.015	0.008	0.079	0.100	0.112	0.139	0.282
BPRFM	0.729	0.703	0.034	0.027	0.012	0.016	0.003	0.031	0.045	0.075	0.117	0.199
KGNN-LS	0.783	0.721	0.031	0.026	0.014	0.011	0.002	0.028	0.045	0.057	0.145	0.213
KGIN	0.801	0.729	0.037	0.029	0.013	0.013	0.006	0.019	0.066	0.108	0.151	0.222
CKAN	0.792	0.749	0.046	0.034	0.015	0.007	0.009	0.089	0.114	0.122	0.216	0.303
MKR	0.785	0.756	0.042	0.038	0.027	0.012	0.012	0.082	0.094	0.142	0.163	0.288
KMRH	0.782	0.768	0.046	0.032	0.028	0.015	0.011	0.082	0.093	0.145	0.193	0.245
DEKGCL	0.795	0.757	0.043	0.030	0.024	0.011	0.009	0.091	0.092	0.162	0.185	0.242
KGMG	0.803	0.782	0.049	0.033	0.026	0.018	0.012	0.063	0.099	0.173	0.282	0.309

3.4 消融实验和超参数灵敏度分析

通过消融实验和超参数灵敏度分析与基线模型 (MKR) 对比, 验证 KGMG 算法每个改进点和实验超参数的有效性.

为验证本方法中特征交叉压缩单元和与显式和潜在用户兴趣建模对模型性能的影响, 设计如下消融实验: N1: 在推荐模块中, 仅采用图结构增强和知识图谱嵌入模块, 依赖用户与项目的交互图信息, 未采用潜在用户兴趣建模; N2: 在模型中采用特征交叉压缩单元, 潜在用户兴趣建模、知识图谱嵌入模块和特征交叉压缩单元, 未引入图结构增强模块, 直接利用用户和项目的原始特征向量, 并将其反馈到嵌入层 (T); N3: 采用特征交叉压缩单元、显式与潜在用户兴趣建模, 知识图谱嵌入模块中尾实体 (t) 和关系 (r) 未使用 CNN 提取特征向量. N4: 在特征交叉压缩单元中, 采用两个特征交叉压缩单元 (T) 处理图结构增强输出的项目特征和知识图谱嵌入模块的头实体.

表 4 为模型的消融实验结果, 在 CTR (点击率) 任务中, 未采用重构潜在用户兴趣建模模型性能降低, 说明通过 Tri-GNN 逐层获取用户和项目直接、间接和更

深层次的关系, 有效提取用户多层次兴趣, 解决数据稀疏性问题. 在没有图结构增强的情况下, 模型性能下降, 表明根据评分权重随机删除用户和项目和利用编码器聚合分析用户和项目节点的多跳邻居关系效果更好. 相较于原知识图谱嵌入模块中不使用 CNN 无法有效提取关系 (r)、头实体 (h) 的局部特征, 预测尾实体 (t) 的准确性下降, 证明 CNN 能够有效地对其降维、压缩, 保留关键特征, 去除冗余信息, 准确预测关系实体和尾实体. 原模型使用两个特征交叉压缩单元 AUC 和 ACC 指标均下降, 这是因为在训练过程中出现过拟合问题, KGMG 算法仅使用一个特征交叉压缩单元 (T) 可以加快训练过程, 使得模型更快地收敛, 避免过拟合.

表 4 模型消融研究

算法	Book-Crossing		Last.FM	
	AUC	ACC	AUC	ACC
MKR	0.730	0.693	0.785	0.756
N1	0.732	0.687	0.785	0.741
N2	0.736	0.693	0.783	0.732
N3	0.745	0.682	0.789	0.715
N4	0.735	0.693	0.769	0.708
KGMG	0.763	0.717	0.803	0.782

为验证 KGMG 算法在稀疏场景下的性能, 通过调整训练集比例 r 模拟不同的稀疏场景, 并将 KGMG 算法与近两年最新算法 (KMRH、DEKGCL) 和流行算法 (MKR、KGAT、KGIN) 进行比较, 通过 AUC 指标衡量模型效果, 实验结果如表 5 所示。

表 5 稀疏数据集中, 不同训练集比例 r 下不同推荐算法性能对比

模型	100%	80%	60%	40%	20%	10%
MKR	0.730	0.715	0.686	0.643	0.629	0.613
KGAT	0.735	0.711	0.675	0.656	0.622	0.601
KGIN	0.743	0.725	0.698	0.683	0.611	0.598
KMRH	0.724	0.713	0.702	0.696	0.685	0.675
DEKGCL	0.745	0.726	0.718	0.695	0.688	0.683
KGMG	0.763	0.759	0.752	0.748	0.741	0.735

在这组实验中, 通过设置不同的训练集比例, 在保证测试集不变的情况下, 共进行了 10 次实验。可以看出随着数据集稀疏程度的增大, 各推荐模型效果都有所下降。相对于 $r=100%$, 当 $r=10%$ 时, 各基线模型 AUC 指标下降幅度较大, 其中 KGIN 模型下降高达 14.5%, 最低的 MKR 模型下降 11.7%, 而 KGMG 算法只下降 2.8%, 这表明在更为稀疏场景下, KGMG 算法通过知识图谱补充额外信息, 使得项目向量的表示更准确, 同时经过根据权重随机删除的方式提取特征后, 可以缓解数据稀疏性问题。

为确定知识图谱嵌入维度、图卷积层数和学习率参数设置灵敏度分析, 并确定最优数值, 在处理交互较少的用户时的鲁棒性, 根据文献[38]的方法生成一个稀疏用户集。Book-Crossing 数据集中交互少于 20 次的用户, 以及 Last.FM 数据集中交互少于 5 次的用户被归入此集。KGMG 模型与基础模型 (MKR) 和传统模型 (KGIN、KGAT) 相比, 这些稀疏用户的结果在图 2 中进行分析。

卷积层数 L 的影响: 随着卷积层数的增加, 模型的性能在所有数据集上均呈现下降趋势, 当卷积层数达到 4 层时, 其性能开始下降, 如图 3 所示, 由于网络深度增加导致节点融合过多邻居信息, 引起节点特有信息的弱化和过平滑问题。

嵌入维度: 嵌入维度变化的结果如图 4 所示, 随着嵌入维度增加, 模型性能先是提升, 并在嵌入维度达到 64 时达到最佳。超过 64 后, 模型性能开始下降, 因为过高的嵌入维度引起过拟合, 从而降低模型的泛化能力, 基于实验结果, 确定 64 为模型的最佳嵌入维度。


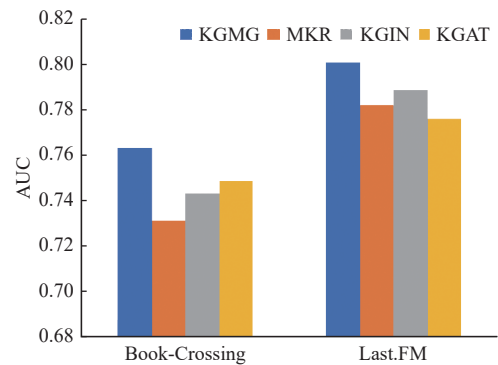


图 2 冷启动用户比较

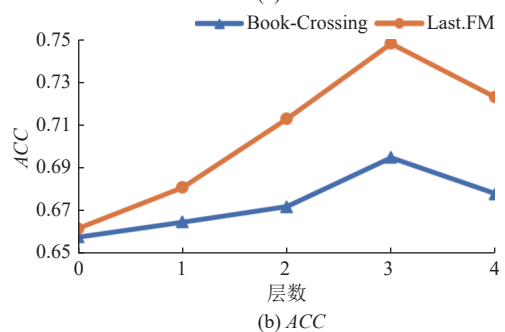



图 3 卷积层数

学习率: 当学习率从 10^{-5} 增加到 10^{-4} 时, 模型在 AUC 和 ACC 的性能均有所提升, 继续提高学习率会导致性能下降, 因为过高的学习率导致模型在训练过程中无

法稳定收敛, 过低可能导致模型参数更新过于缓慢, 使得模型在训练过程中收敛速度变慢, 如图 5 所示, 过高或过低的学习率都对模型性能产生不利影响, 因此将学习率设置为 10^{-4} 是最佳选择。




图 4 嵌入维度




图 5 学习率

4 结论与展望

目前, 大多数的推荐系统中用户-项目交互图中的数据稀疏性和冷启动问题会影响推荐准确性和解释性的能力, 针对以上问题提出基于知识图谱的用户兴趣推荐算法. 该算法从用户潜在兴趣和用户显式兴趣对用户兴趣建模, 使用多层图神经网络提取用户和项目的细粒度特征来解决用户兴趣的数据稀疏性问题. 使用图结构增强随机删除用户和项目的关系, 充分利用知识图谱中蕴含的丰富语义和独特的网络结构, 挖掘用户的显式兴趣, 解决用户兴趣的冷启动问题. 对知识图谱嵌入模块通过 CNN 处理关系 (r) 和尾实体 (t) 捕捉用户与项目之间的交互关系, 能够提供更加精准和多样化的推荐结果. 在 Book-Crossing 和 Last.FM 数据集上进行实验, 证明该算法的有效性. 在未来的工作中, 将致力于 Top-K 预测, 更有效地处理稀疏数据, 使用知识图谱、异构图和图卷积来解决冷启动问题, 利用轻量级图卷积网络, 用于重构潜在用户与项目特征语义关系提取, 减少训练时间, 继续寻求创建更有效和更可解释的推荐模型, 并扩展本文提出的用于文章推荐的框架.

参考文献

- Wang DJ, Zhang X, Yu DJ, *et al.* CAME: Content-and context-aware music embedding for recommendation. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(3): 1375–1388. [doi: 10.1109/TNNLS.2020.2984665]
- 周洋涛, 褚华, 朱非非, 等. 基于深度学习的个性化学习资源推荐综述. *计算机科学*, 2024, 51(10): 17–32. [doi: 10.11896/jsjcx.240400088]
- Hu HC, Guo W, Liu X, *et al.* User behavior enriched temporal knowledge graphs for sequential recommendation. *Proceedings of the 17th ACM International Conference on Web Search and Data Mining*. Merida: ACM, 2024. 266–275.
- Xue F, He XN, Wang X, *et al.* Deep item-based collaborative filtering for top-N recommendation. *ACM Transactions on Information Systems (TOIS)*, 2019, 37(3): 33.
- 高仰, 刘渊. 融合社交关系和知识图谱的推荐算法. *计算机科学与探索*, 2023, 17(1): 238–250.
- Wang X, He XN, Wang M, *et al.* Neural graph collaborative filtering. *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Paris: ACM, 2019. 165–174.
- Wang X, Wang DX, Xu CR, *et al.* Explainable reasoning over knowledge graphs for recommendation. *Proceedings of the 33rd AAAI Conference on Artificial Intelligence*. Honolulu: AAAI Press, 2019. 5329–5336.
- Zhang JC, Zain AM, Zhou KQ, *et al.* A review of recommender systems based on knowledge graph embedding. *Expert Systems with Applications*, 2024, 250: 123876. [doi: 10.1016/j.eswa.2024.123876]
- Kazemi SM, Goel R, Jain K, *et al.* Representation learning for dynamic graphs: A survey. *The Journal of Machine Learning Research*, 2020, 21(1): 70.
- 赵晔辉, 柳林, 王海龙, 等. 知识图谱推荐系统研究综述. *计算机科学与探索*, 2023, 17(4): 771–791. [doi: 10.3778/j.issn.1673-9418.2205052]
- Dadoun A, Troncy R, Ratier O, *et al.* Location embeddings for next trip recommendation. *Proceedings of the 2019 World Wide Web Conference*. San Francisco: ACM, 2019. 896–903.
- Shi C, Hu BB, Zhao WX, *et al.* Heterogeneous information network embedding for recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 31(2): 357–370. [doi: 10.1109/TKDE.2018.2833443]
- Wang HW, Zhang FZ, Xie X, *et al.* DKN: Deep knowledge-aware network for news recommendation. *Proceedings of the 2018 Web Conference on World Wide Web*. Lyon: ACM, 2018. 1835–1844.
- Zhang FZ, Yuan NJ, Lian DF, *et al.* Collaborative knowledge

- base embedding for recommender systems. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016. 353–362.
- 15 Wang HW, Zhang FZ, Zhao M, *et al.* Multi-task feature learning for knowledge graph enhanced recommendation. Proceedings of the 2019 World Wide Web Conference. San Francisco: ACM, 2019. 2000–2010.
- 16 Ye YT, Wang XW, Yao CJ, *et al.* Bayes EMbedding (BEM): Refining representation by integrating knowledge graphs and behavior-specific networks. Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing: ACM, 2019. 679–688.
- 17 Scarselli F, Gori M, Tsoi A C, *et al.* The graph neural network model. IEEE Transactions on Neural Networks, 2008, 20(1): 61–80. [doi: [10.1109/TNN.2008.2005605](https://doi.org/10.1109/TNN.2008.2005605)]
- 18 Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. arXiv:1609.02907, 2016.
- 19 Guo L, Liu H, Zhu L, *et al.* DA-DAN: A dual adversarial domain adaption network for unsupervised non-overlapping cross-domain recommendation. ACM Transactions on Information Systems, 2024, 42(2): 48.
- 20 Yu JL, Xia X, Chen T, *et al.* XSimGCL: Towards extremely simple graph contrastive learning for recommendation. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(2): 913–926.
- 21 Chen JW, Dong HD, Wang X, *et al.* Bias and debias in recommender system: A survey and future directions. ACM Transactions on Information Systems, 2023, 41(3): 67.
- 22 Chen ZL, Wu ZH, Sadikaj Y, *et al.* ADEdgeDrop: Adversarial edge dropping for robust graph neural networks. arXiv:2403.09171, 2024.
- 23 Connelly M, Sinclair L, Dubois S, *et al.* Interest-aware message passing recommender model based on graph convolutional networks. Journal of Latex Class Files, 2015, 14(8): 1–8.
- 24 Wang X, He XN, Cao YX, *et al.* KGAT: Knowledge graph attention network for recommendation. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: ACM, 2019. 950–958.
- 25 Wang X, Huang TL, Wang DX, *et al.* Learning intents behind interactions with knowledge graph for recommendation. Proceedings of the 2021 Web Conference. Ljubljana: ACM, 2021. 878–887.
- 26 张俊三, 肖森, 高慧, 等. 基于邻域采样的多任务图推荐算法. 计算机工程与应用, 2024, 60(9): 172–180. [doi: [10.3778/j.issn.1002-8331.2308-0212](https://doi.org/10.3778/j.issn.1002-8331.2308-0212)]
- 27 杨智伟, 张帆, 杨志, 等. 基于用户信息融合的图卷积网络报表推荐算法. 电力建设, 2023, 44(5): 43–52. [doi: [10.12204/j.issn.1000-7229.2023.05.005](https://doi.org/10.12204/j.issn.1000-7229.2023.05.005)]
- 28 李鹏飞, 贺洋, 毋建宏. 融合全局特征的时空网络兴趣点推荐算法. 计算机工程与应用, 2024, 60(11): 75–83. [doi: [10.3778/j.issn.1002-8331.2303-0168](https://doi.org/10.3778/j.issn.1002-8331.2303-0168)]
- 29 He X, Deng K, Wang X, *et al.* LightGCN: Simplifying and powering graph convolution network for recommendation. Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020. 639–648.
- 30 Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems. Computer, 2009, 42(8): 30–37. [doi: [10.1109/MC.2009.263](https://doi.org/10.1109/MC.2009.263)]
- 31 Lee G, Yang E, Hwang SJ. Asymmetric multi-task learning based on task relatedness and loss. Proceedings of the 33rd International Conference on Machine Learning. New York: JMLR.org, 2016. 230–238.
- 32 Wang H, Zhang F, Zhang M, *et al.* Knowledge-aware graph neural networks with label smoothness regularization for recommender systems. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019. 968–977.
- 33 He ZY, Wang CD, Wang JF, *et al.* Community enhanced knowledge graph for recommendation. IEEE Transactions on Computational Social Systems, 2024, 11(5): 5789–5802. [doi: [10.1109/TCSS.2024.3383603](https://doi.org/10.1109/TCSS.2024.3383603)]
- 34 Wang Z, Lin GY, Tan HB, *et al.* CKAN: Collaborative knowledge-aware attentive network for recommender systems. Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2020. 219–228.
- 35 Sun Z, Fang H, Yang J, *et al.* DaisyRec 2.0: Benchmarking recommendation for rigorous evaluation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(7): 8206–8226. [doi: [10.1109/TPAMI.2022.3231891](https://doi.org/10.1109/TPAMI.2022.3231891)]
- 36 Yang YJ, Zeng ZY, Jiang SY, *et al.* DEKGI: A double-ended recommendation model for integrating knowledge graph and user-item interaction graph. The Journal of Supercomputing, 2024, 80(16): 24781–24800. [doi: [10.1007/s11227-024-06344-x](https://doi.org/10.1007/s11227-024-06344-x)]
- 37 Zhu JL, Zhang YH, Wang YL, *et al.* Knowledge-enhanced multi-task recommendation in hyperbolic space. Applied Intelligence, 2023, 53(23): 28694–28710. [doi: [10.1007/s10489-023-05045-x](https://doi.org/10.1007/s10489-023-05045-x)]
- 38 Yu JL, Yin HZ, Li JD, *et al.* Self-supervised multi-channel hypergraph convolutional network for social recommendation. Proceedings of the 2021 Web Conference. Ljubljana: ACM, 2021. 413–424.

(校对责编: 张重毅)