

DOI:10.13232/j.cnki.jnju.2026.02.008

基于个人知识图谱表示学习的推荐算法

王晨旭^{1,2*}, 沈彦成¹, 胡 骏¹, 王世豪¹

(1. 西安交通大学软件学院, 西安, 710049; 2. 智能网络与网络安全教育部重点实验室(西安交通大学), 西安, 710049)

摘要:随着互联网技术的快速发展,推荐系统在解决信息过载问题中发挥着越来越重要的作用,然而,传统推荐方法往往忽视了用户个性化特征与物品之间的复杂潜在关联,导致推荐效果不理想.针对这一问题,提出一种基于个人知识图谱的特征交互图神经网络推荐模型(PKGRec),将用户个人知识图谱与公共知识图谱进行融合,通过特征实体交互层捕获实体间的复杂交互模式.同时,设计了偏好感知注意力机制,根据用户对不同交互物品的权重信息进行细粒度的用户表示学习,有效提升了模型的表达能力.为了验证模型的有效性,在网易云音乐和 KuaiRec 两个真实大规模数据集上进行了实验.实验结果表明,和 BPRMF, NFM, CKE 等八种主流基线方法相比,PKGRec 模型的三个评估指标 *Precision*, *Recall* 和 *NDCG* 均取得了显著提升,特别是在处理冷启动和长尾推荐问题时表现出明显优势,验证了个人知识图谱在增强推荐系统方面的有效性.

关键词:个人知识图谱,推荐系统,图神经网络,特征交互,注意力机制

中图分类号:TP311.13, TP309

文献标志码:A

Recommendation algorithms based on personalized knowledge graph representation learning

Wang Chenxu^{1,2*}, Shen Yancheng¹, Hu Jun¹, Wang Shihao¹

(1. School of Software Engineering, Xi'an Jiaotong University, Xi'an, 710049, China;

2. Ministry of Education Key Lab for Intelligent Networks and Network Security,
Xi'an Jiaotong University, Xi'an, 710049, China)

Abstract: With the rapid development of Internet technology, recommendation systems are playing an increasingly important role in addressing information overload. However, traditional recommendation methods often overlook the complex latent relationships between users' personalized features and items, leading to suboptimal performance. To tackle this issue, we propose PKGRec, a Feature-Interactive Graph Neural Network recommendation model based on Personal Knowledge Graphs. PKGRec integrates users' personal knowledge graphs with public knowledge graphs and captures complex interaction patterns among entities through a feature-entity interaction layer. Furthermore, we design a preference-aware attention mechanism that enables fine-grained user representation learning based on the user's interaction weights with different items, effectively enhancing the model's expressive power. We evaluate our model on two large-scale real-world datasets: NetEase Cloud Music and KuaiRec. Experimental results show that PKGRec significantly outperforms eight strong baselines, including BPRMF, NFM, and CKE, across three evaluation metrics: *Precision*, *Recall*, and *NDCG*. Notably, PKGRec exhibits significant advantages in cold-start and long-tail recommendation scenarios, validating the effectiveness of personal knowledge graphs in enhancing recommendation systems.

基金项目:国家自然科学基金(62272379, T2341003),陕西省自然科学基金基础研究计划(2025JC-JCQN-081),中央高校基本科研业务费专项资金(xzy012023068),西安交通大学人工智能研究基金(2025YXYC004)

收稿日期:2025-09-03

* 通信联系人, E-mail: cxwang@mail.xjtu.edu.cn

Keywords: personalized knowledge graph, recommendation system, graph neural network, graph neural network, attention mechanism

在大数据时代,个性化推荐系统通过分析用户的行为特征,从海量信息中精准匹配用户兴趣偏好,有效提升了信息获取效率^[1-3]。然而,传统的推荐算法主要依赖用户的历史行为数据和物品的特征信息^[4],由于用户通常只与少量物品产生交互,所以用户-物品交互矩阵极其稀疏,导致传统的推荐算法忽视了用户个体之间的差异性和动态变化性,存在知识利用不充分的问题,难以及时响应用户兴趣的变化。同时,基于深度学习的方法需要大量的训练数据,对于稀疏数据和冷启动的场景容易出现过拟合^[5]。这些问题严重影响了推荐系统的性能和用户体验。

知识图谱推荐是近来个性化推荐领域的研究热点,它通过将用户和物品与知识图谱中的相关实体相联系,利用图谱中的丰富关联信息(如人物、地点、物品及其关系)来改进推荐效果。尽管基于知识图谱的推荐方法在处理冷启动和长尾推荐等问题上取得了一定的研究进展,现有方法仍存在不足。首先,这些方法主要关注通用知识图谱,忽视了用户个人的知识特征,难以捕获用户的个性化需求和兴趣偏好;其次,现有的基于GNN(Graph Neural Network)的知识图谱推荐方法普遍采用Trans系列或LightGCN的初始化编码方式^[6],需要占用大量的计算资源,而且对于动态变化的图结构适应性能较差,一旦图结构发生变化就需要花费大量时间重新训练^[7],难以满足实时推荐的需求,严重制约了知识图谱推荐方法在实际应用中的效果。

本文提出一种基于个人知识图谱推荐的特征交互图神经网络(PKGRec),根据物品构建公共知识图谱,其中,实体表示各类物品,边表示实体之间的关系。初始阶段对所有实体进行编码,然后利用特征实体交互层对实体邻居聚合过程中实体之间复杂的交互信息进行建模。为了学习更细粒度的用户表示,将用户的交互权重信息集成到用户-物品二部图中,并设计了一个偏好感知注意力机制,利用用户对每个交互物品不同的权重信

息,对用户的表示进行加权聚合。最后,使用最终的用户和物品表示完成评分预测任务。

本文的贡献如下。

(1)设计了特征实体交互编码知识图谱编码方式,设计的特征实体交互层可以融合个人知识图谱和公共知识图谱,通过实体间的复杂交互建模提升推荐效果。该层不仅能够保持图结构的原有特征,还能够自适应地学习不同类型关系的重要性,有效提升了模型对用户兴趣的表示能力。

(2)提出了偏好感知注意力机制,根据用户对不同交互物品的权重信息进行细粒度的用户表示学习。通过引入注意力权重,模型可以更好地区分用户对不同物品的兴趣程度,还有效降低了噪声数据的影响,提高了推荐结果的准确性。

(3)设计了相关性预测模块,使用多层感知机和内积结合方法,可以捕获特征向量间的非线性关联模式与底层图结构的拓扑特性,这种设计能更准确地预测用户对未交互物品的兴趣程度。

在网易云音乐和KuaiRec两个真实数据集上的实验结果表明,提出的方法在处理冷启动和长尾推荐问题时,表现更优。

1 相关工作

1.1 个人知识图谱 知识图谱已成为捕捉并表达结构化人类数据及其属性的重要工具,广泛应用于搜索、推荐和数据挖掘等场景^[8]。公共知识图谱包括通用资源(如维基数据、DBpedia)和特定领域资源(如MusicBrainz,用于音乐信息)。在公共知识图谱当中,实体通常是“足够突出”的人或事物,能够被纳入知识图谱。然而,这种定义排除了许多日常生活中的实体。为此,Balog and Kenter^[9]提出个人知识图谱(Personal Knowledge Graph,PKG)的概念,即一种结构化的信息资源,涵盖与用户个人相关的实体、属性及其关系。

PKG中存储的知识可用于多种以用户为中心的任务,而不仅限于广义知识。例如,Yen et al^[10]提出的PKG连接了用户的生活日志和社交

网络图. Chakraborty et al^[11]提出的学术 PKG 则与 ORKG 等学术知识图谱相连,将个人研究知识图谱(PRKG)用于简化研究人员的日常任务. Yang et al^[12]构建的 PKG 允许系统通过“神经十符号”的方式来跨越不同的服务,为用户提供合理准确的推荐.

1.2 基于知识图谱的推荐 知识图谱推荐是近来个性化推荐领域的研究热点,将用户和物品与知识图谱中的相关实体相联系,利用图谱中的丰富关联信息来改进推荐效果,从更广的知识链接中发掘用户的潜在兴趣^[13]. 现有的知识感知推荐研究主要分以下三类.

1.2.1 基于路径的方法 利用连接用户和物品的元路径的方法,在更大程度上利用用户和物品之间的内在连通性. Jin et al^[14]提出一种通过元路径引导的邻域捕捉节点之间的交互模式,利用快速傅里叶变换实现高效学习. Shi et al^[15]设计了一个多维知识图谱框架,能够根据学习者目标生成个性化学习路径. Li et al^[16]提出的 GEHRL 框架利用高级代理作为子目标选择器,为低级代理确定具体子目标,而低级代理则负责向学习者推荐学习项目.

1.2.2 基于 GNN 的方法 图推荐系统从 GNN 中汲取灵感,通过知识感知聚合来实现高阶信息中端到端的聚合,增强用户和物品的表示学习. Wang et al^[17-19]通过 GNN 模型与注意力机制结合的方法(KGAT, CKANKGIN)在知识图谱增强推荐系统中显著提升了高阶连接建模、协作信号整合和关系序列集成的能力. Tang et al^[20]提出的 EditKG 框架旨在通过编辑推荐知识图谱来平衡物品属性分布,调整属性以消除虚假信息.

1.2.3 基于对比学习的方法 这类方法同样借鉴了 GNN 在端到端聚合高阶信息中的优势,促进了知识图谱中高阶信息的端到端聚合. Yang et al^[21-22]通过设计知识图谱对比学习框架(KG-CL)和 KGRec 自监督合理化方法,有效提升了知识图谱的表示能力并增强了系统的抗噪性. Liang et al^[23]提出一种基于图的非采样策略(GN-SKR),通过局部聚合模块,将知识图谱嵌入与推荐任务有效结合,捕捉高阶连接信息.

2 基于个人知识图谱表示学习的推荐算法

2.1 问题描述 推荐系统的核心目标是根据用户的行为和兴趣,为其筛选并推荐最合适的内容. 整个系统由用户端和项目端两部分组成,各自承担不同的任务.

用户端主要负责提供个性化信息,如浏览、搜索、点赞和购买记录,这些数据帮助系统建立用户画像,提高推荐的精准度. 项目端方面,用户的反馈在项目端优化推荐策略中发挥引导作用,使系统能够不断调整,提供更符合用户偏好的内容.

传统的基于知识图谱的推荐通常使用用户物品交互二部图^[24],把个人知识图谱中的数据抽取出来进行训练和验证. 用户物品交互二部图定义为个人知识图谱 $PKG=(U, V, R, F)$, 其中 $U=\{u_1, \dots, u_N\}$ 表示用户实体的集合, N 表示该网络中共有 N 个用户; $V=\{v_1, \dots, v_M\}$ 表示除用户外实体的集合,每个实体 $v \in V$ 都有标签信息和属性信息(属性信息可以为空), M 表示 PKG 中实体的数量; $R=\{r_1, \dots, r_{P_1}\}$ 为实体之间关系的集合,每个关系 r 都有标签信息和权重属性(用户之间的社交关系无权重属性), P_1 表示关系的数量; $F=\{f_1, \dots, f_{Q_1}\}$ 为事实的集合, Q_1 表示关系的数量;每个三元组 $f=(h, r, t)$ 都表示一个事实, h 表示头实体($h \in U$), r 表示关系类型($r \in R$), t 表示尾实体($t \in (E \cup U)$).

将物品知识图谱定义为公共知识图谱 $CKG=(E, R, F)$, $E=\{e_1, \dots, e_I\}$ 表示所有物品的集合, I 表示 PKG 中实体的数量; $R=\{r_1, \dots, r_{P_2}\}$ 为实体之间关系的集合, P_2 表示关系的数量; $F=\{f_1, \dots, f_{Q_2}\}$ 为事实的集合, Q_2 表示关系的数量. 本研究通过 ID 映射来合并个人知识图谱和公共知识图谱,这相当于在 PKG 和 CKG 之间建立一座桥梁. 设 $A=\{(v, e) | v \in V, e \in E\}$ 为 ID 映射操作,其中, (v, e) 表示物品与实体的对齐集合.

综上,本研究的推荐任务定义如下:给定个人知识图谱 PKG 和公共知识图谱 CKG,目标是预

测用户是否对以前没有与之交互的物品有潜在的兴趣.任务是学习一个预测函数,如式(1)所示:

$$\hat{y}_{uv} = F(u, v | \Theta, PKG, CKG) \quad (1)$$

其中, \hat{y}_{uv} 表示用户 u 对物品 v 的交互概率, Θ 表示函数 F 的参数集合.

2.2 PKGRec 模型设计 模型的框架如下图所

示.该模型由四部分组成:映射匹配层通过 ID 映射 PKG 和 CKG 中的实体;嵌入层将所有的节点参数化为编码向量;聚合层使用不同的聚合方式分别聚合 CKG 和 PKG 的邻居信息,得到用户和物品的最终表示;预测层利用多层感知机和欧几里得内积捕捉用户与物品之间的潜在关系,完成评级预测任务.

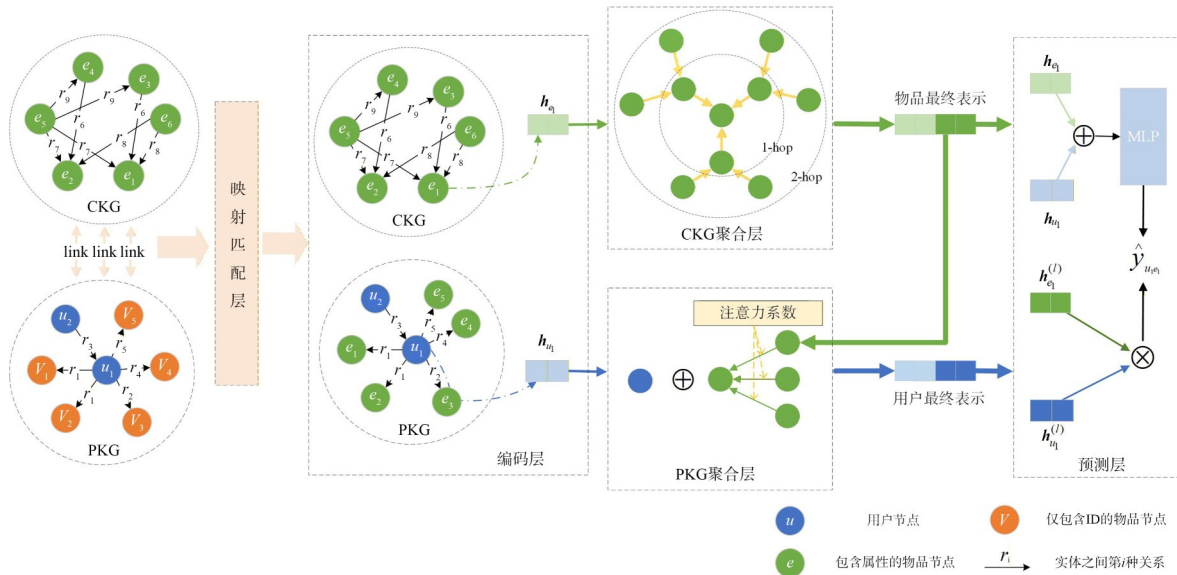


图 基于个人知识图谱推荐的特征交互神经网络整体框架

Fig The overall framework of PKGRec

2.3 映射匹配对齐嵌入 映射匹配层的主要任务是对 PKG 和 CKG 中的实体进行对齐和映射.在知识图谱中,PKG 主要包含用户个体的兴趣偏好信息,而 CKG 则包含物品之间的外部关系信息.由于两者的数据来源不同,因此需要通过 ID 映射的方式将 PKG 中的实体对齐到 CKG 中的相应实体,实现跨图谱的信息共享.在数据构建阶段,每个实体都会被分配一个唯一的标识符(ID)并存储于 PKG 和 CKG 中.对于 PKG 中的实体,可以直接采用相同的 ID 进行映射,使其与 CKG 中的实体对齐.

知识图谱嵌入是在保持图结构的前提下,将实体和关系参数化为向量表示的方法.嵌入层的主要任务是对个人知识图谱 PKG 和公共知识图谱 CKG 中的所有节点进行参数化,并将其映射为低维向量表示,为后续的关系建模和推荐任务提供基础.模型对 PKG 和 CKG 中的实体属性进行

编码.针对不同类别属性信息的实体,模型分别采用 one-hot 编码、分级编码和数值编码等方法对其属性信息进行向量化处理.

2.4 特征交互聚合 在得到初始的实体嵌入表示后,模型首先对来自不同邻居节点的特征信息进行聚合.由于 CKG 和 PKG 的结构和信息来源存在较大差异,聚合层采用不同的策略分别处理两类图谱的信息.

2.4.1 CKG 聚合层 由于 CKG 中包含了大量关于物品之间外部关系的结构化知识,聚合层会采用关系感知的聚合方法.假设物品实体 e_i 与邻居节点 e_j 之间存在关系 r ,为每种关系分配独立的权重矩阵 W_r ,并引入一个拼接函数 \oplus 来融合关系信息与邻居节点表示.聚合操作为:

$$h_{e_i}^{(l+1)} = \sigma \left(W_0 h_{e_i}^{(l)} \oplus \sum_{r \in R} \sum_{e_j \in N_r(e_i)} W_r h_{e_j}^{(l)} \right) \quad (2)$$

其中, R 表示所有关系类型的集合, W_0 表示权重

矩阵, $N_r(e_i)$ 表示与实体 e_i 通过关系 r 连接的邻居实体, σ 表示激活函数, $\mathbf{h}_{e_i}^{(l)}$ 表示第 l 层实体 e_i 的嵌入表示.

聚合操作完成之后, 拼接实体最开始的嵌入表示 $\mathbf{h}_{e_i}^{(0)}$, 得到物品实体 e_i 的最终表示 \mathbf{h}_{e_i} . 拼接方法如下所示:

$$\mathbf{h}_{e_i} = \text{concat}(\mathbf{h}_{e_i}^{(0)}, \mathbf{h}_{e_i}^{(L)}) \quad (3)$$

2.4.2 PKG 聚合层 个人知识图谱中的信息主要反映用户个体的兴趣偏好, 聚合操作侧重于用户的历史行为和交互数据. 用户 u 对于交互过的物品的聚合方式如下所示:

$$\tilde{\mathbf{h}} = \sum_{e \in N(u)} \alpha_{ue} \mathbf{h}_e \quad (4)$$

其中, $N_e(u)$ 表示用户 u 的交互物品集合, α_{ue} 是通过用户的行为记录得到的权重. 每次交互都会增加某个权重, 权重还会随着时间的延长而降低, 反映了用户 u 对物品 e 的偏好程度.

在用户交互物品的聚合阶段完成后, 为了进一步提升用户表示的细粒度和全局性, 引入基于社交网络的聚合机制. 设用户 u 的邻居用户集合为 $N_v(u)$, 包括用户关注的人和关注该用户的人. 用户 u 的增强表示可通过对邻居用户表示进行加权聚合得到, 如下所示:

$$\mathbf{h}'_u = \lambda_1 \tilde{\mathbf{h}}_u + (1 - \lambda_1) \frac{1}{|N_v(u)|} \sum_{v \in N_v(u)} \tilde{\mathbf{h}}_v \quad (5)$$

其中, λ_1 是超参数, $N_v(u)$ 表示用户 u 的社交邻居集合, $|N_v(u)|$ 表示用户 u 的社交邻居数量.

聚合操作完成后也需要拼接实体最开始的嵌入表示 \mathbf{h}'_u , 以得到最终的用户表示 \mathbf{h}_u . 拼接方法如下所示:

$$\mathbf{h}_u = \text{concat}(\mathbf{h}'_u, \mathbf{h}_u) \quad (6)$$

聚合层通过两种不同的策略对公共知识图谱与个人知识图谱中的信息进行整合: 公共知识图谱利用关系感知聚合方法捕捉多种关系的语义信息, 个人知识图谱则通过加权聚合和注意力机制聚合用户历史行为与社交网络数据, 最终生成信息特征融合的用户和物品表示.

2.5 预测与优化 预测层负责计算用户与物品之间的潜在匹配度, 生成最终的推荐结果. 为了捕捉用户与物品间复杂的非线性关系和相似性,

本研究采用了三种方法.

第一种, 通过多层感知机进行预测, 学习输入特征的非线性关系, 生成用户与物品的匹配分数. 方法如下所示:

$$\hat{y}_{uv} = \sigma(\mathbf{W}_2 \text{concat}(\mathbf{h}_u, \mathbf{h}_e) + b) \quad (7)$$

其中, \mathbf{W}_2 是权重矩阵, \mathbf{h}_u 表示用户 u 的最终表示, \mathbf{h}_e 表示物品 e 的最终表示.

第二种, 通过欧几里得内积进行预测, 能够量化用户与物品之间的语义接近度. 方法如下:

$$\hat{y}_{uv} = \mathbf{h}_u^T \mathbf{h}_e \quad (8)$$

第三种方法将上述两种方式结合起来进行预测, 如式(9)所示, 使用用户和物品的初始向量通过多层感知机, 之后使用通过聚合得到的用户向量 \mathbf{h}'_u 与物品向量 $\mathbf{h}_e^{(l)}$ 之间的欧几里得距离, 取负后作为匹配分数, 使得距离越小(即相似度越高), 对应的匹配分数越高.

$$\hat{y}_{uv} = \lambda_2 (\sigma(\mathbf{W}_3 \text{concat}(\mathbf{h}_u, \mathbf{h}_e)) + b) + (1 - \lambda_2) (\mathbf{h}'_u^T \mathbf{h}_e) \quad (9)$$

为了优化模型, 采用 Bayesian Personalized Ranking (BPR) 损失. BPR 损失是一种广泛用于推荐系统的对偶排序损失函数, 旨在最大化正样本与负样本之间的评分差异, 使用户对正样本的偏好高于负样本. BPR 损失定义为:

$$L_{\text{BPR}} = - \sum_{(u,i,j) \in D} \ln \sigma(\hat{y}_{u,i} - \hat{y}_{u,j}) + \lambda_3 \|\Theta\|^2 \quad (10)$$

其中, (u, i, j) 表示在数据集中用户 u 对正样本物品 i 的交互概率应高于负样本物品 j 的交互概率, σ 是 sigmoid 函数, λ_3 为正正则化系数, $\|\Theta\|$ 表示模型参数正则化.

3 实验验证

为了探究 PKGRec 模型的有效性并与现有的多种推荐算法进行对比分析, 进行了如下实验.

(1) 实验设置与参数调优. 详细描述实验环境、硬件配置和超参数设置, 并调整不同的参数值来验证 PKGRec 模型在不同设置下的性能表现.

(2) 数据集分析. 使用 KuaiRec 公开数据集和网易云音乐数据集, 详细介绍了数据集的规模、数据特性以及特征提取方法.

(3) 大规模数据验证. 采用 *Precision*, *Recall*

和 *NDCG* 三种常用指标,对比分析 PKGRec 模型在大规模数据集上的推荐准确性和排序效果上的表现,验证模型的推荐性能。

(4) 对比算法分析. 与 BPRMF, NFM, CKE, ECFKG, KGAT, KGCL, KGIN 和 KGRec 等多种基线算法进行对比,评估 PKGRec 模型在处理冷启动和长尾推荐问题上的优势。

3.1 数据集分析 为了评估 PKGRec 模型的有效性,使用 KuaiRec 和网易云音乐两个数据集进行实验,数据集的具体信息如表 1 所示。

(1) KuaiRec 数据集. 由快手与中国科学院发布,包含用户在短视频平台上的显式与隐式交互记录、内容特征及用户画像,分为 Small_matrix 和 Big_matrix,分别用于评测和训练. 数据处理包括提取用户特征、视频特征、社交关系和知识图谱信息,并转化为适合图嵌入的 PyTorch 张量。

(2) 网易云音乐数据集. 通过数据库连接池技术获取用户听歌记录及交互信息. 数据经过去重和筛选,构建了用户-歌曲交互矩阵和公共知识图谱,按 8:2 的比例分为训练集和测试集,采用多线程处理和自定义规则进行数据整合。

表 1 数据集的信息表

Table 1 Information table of datasets

数据集	用户数	物品数	交互数	关系数
KuaiRec	7176	10729	12530806	2
网易云音乐	4684	30593	2217661	5

3.2 实验设置 为了全面评估 PKGRec 模型的有效性,选取八种代表性推荐模型作为基线,涵盖了传统协同过滤、神经网络增强以及知识图谱融合等不同技术范式,在上述两个数据集上与以下基线模型进行了对比。

(1) BPRMF^[25]. 通过矩阵分解技术来优化个性化排序任务,特别适用于处理隐式反馈数据。

(2) NFM^[26]. 将因子分解机嵌入深度神经网络框架,引入非线性隐藏层来增强特征交互建模能力,实现高阶特征组合的自动学习。

(3) CKE^[27]. 融合 TransR 语义嵌入与协同过滤框架,结合知识图谱嵌入正则化来增强用户-物品表示,利用结构化语义关系辅助推荐任务。

(4) ECFKG^[28]. 将知识图谱的实体与关系嵌

入整合到协同过滤中,利用图谱中的上下文信息丰富表示空间,提升推荐准确性。

(5) KGAT^[29]. 采用图注意力网络显式建模知识图谱中的高阶关系,通过注意力机制区分不同邻居节点的重要性,逐层聚合信息,在复杂关系挖掘方面表现突出。

(6) KGCL^[21]. 引入对比学习策略,在知识图谱和用户行为间构建多视图表示,通过自监督方式来提升物品嵌入的判别能力,有效应对数据稀疏和噪声问题。

(7) KGIN^[19]. 递归地挖掘用户-物品间的潜在关系路径,将多层级图信息融入最终表示,增强模型对稀疏数据的适应性,以提升冷启动场景性能。

(8) KGRec^[12]. 采用自监督学习来整合知识图谱与交互数据,以优化小样本场景下的泛化能力。

所有实验使用 *Precision@K*, *Recall@K* 和 *NDCG@K* 三项指标来全面衡量模型的推荐性能. 此外,还设计了特定的测试场景来深入分析各模型在冷启动用户和长尾物品推荐中的表现差异。

实验的操作系统为 Ubuntu 20.04.6, CPU 为 Intel® Xeon® Gold 6267C, 显卡为 GeForce RTX 3090 显卡,开发语言为 Python 3.8,并在 CUDA 11.6 环境下实现 GPU 加速. 在模型训练的过程中,各项超参数的设置如下:模型中嵌入向量的维度为 64;采用 Adam 优化器,并将初始学习率固定为 0.001;训练过程中的 *Batch size* = 500,训练周期 *Epochs* = 500. 还对其他关键参数进行了实验调优,设定 $\lambda_1 = 0.5$, $\lambda_2 = 0.6$ 和 $\lambda_3 = 0.8$,以验证模型性能。

3.3 实验效果分析 PKGRec 模型有效融合了用户的行为数据与外部知识,提升了个性化推荐任务中的准确性与鲁棒性. 为了验证 PKGRec 在个性化推荐中的性能,在 KuaiRec 和网易云音乐数据集上进行了系统的实验,并将其与八种基线模型进行了对比. 实验结果如表 2 和表 3 所示,表中黑体字表示最优的结果,下划线表示次好的结果。

表 2 KuaiRec 数据集实验结果

Table 2 Experimental results of the KuaiRec dataset

	Precision@	Recall@	NDCG@	Precision@	Recall@	NDCG@
	10	10	10	20	20	20
BPRMF	0.0626	0.0035	0.0640	0.0608	0.0066	0.0614
NFM	0.0634	0.0037	0.0632	0.0613	0.0071	0.0601
CKE	0.0655	0.0040	0.0646	0.0610	0.0101	0.0619
ECFKG	0.0639	0.0039	0.0594	0.0434	0.0096	0.0435
KGAT	0.0644	0.0031	0.0545	0.0504	0.0122	0.0476
KGCL	0.0646	0.0032	0.0553	0.0564	0.0137	0.0574
KGIN	0.0656	<u>0.0041</u>	0.0644	0.0614	0.0144	<u>0.0622</u>
KGRec	<u>0.0657</u>	0.0039	<u>0.0647</u>	<u>0.0664</u>	<u>0.0153</u>	0.0619
PKGRec	0.0677	0.0042	0.0658	0.0681	0.0158	0.0634

表 3 网易云音乐数据集实验结果

Table 3 Experimental results of the NetEase Cloud Music dataset

	Precision@	Recall@	NDCG@	Precision@	Recall@	NDCG@
	10	10	10	20	20	20
BPRMF	0.0633	0.0175	0.0634	0.0663	0.0434	0.0602
NFM	0.0642	0.0186	0.0602	0.0651	0.0455	0.0613
CKE	0.0614	0.0190	0.0611	0.0582	0.0418	0.0641
ECFKG	0.0651	0.0195	0.0657	0.0530	0.0430	0.0547
KGAT	0.0620	0.0173	0.0634	0.0583	0.0383	0.0556
KGCL	0.0701	0.0172	0.0649	0.0642	0.0449	0.0574
KGIN	0.0713	0.0195	<u>0.0707</u>	0.0640	<u>0.0466</u>	0.0662
KGRec	<u>0.0719</u>	<u>0.0207</u>	0.0702	<u>0.0665</u>	0.0462	<u>0.0665</u>
PKGRec	0.0733	0.0216	0.0724	0.0685	0.0477	0.0676

由表可见,对于所有的评估指标,PKGRec 均取得了最优结果,表明其在推荐系统的精确性、覆盖能力及排序质量上具有综合优势。而且,基于知识图谱的模型(CKE, ECFKG, KGAT, KGCL 等)普遍优于传统协同过滤方法(BPRMF, NFM),验证了知识图谱在丰富语义关联、缓解数据稀疏性上的有效性。KuaiRec 数据集的召回率低于网易云音乐数据集是因为在 KuaiRec 的测试集中,用户交互数据较多,而在网易云音乐数据集中每个用户最多有 20 条,所以召回率相对高一点。

PKGRec 的精确度显著高于其他模型,表明其在前 10 推荐结果中能够更精准地筛选出用户感兴趣的内容,这可能得益于个人知识图谱(PKG)的动态建模能力,通过融合用户个性化实

体(如兴趣、社交关系等)来减少通用知识图谱中的噪声干扰,提升推荐相关性。

Recall 的提升反映 PKGRec 能够覆盖更多用户潜在感兴趣的项目,个人知识图谱可以通过长尾兴趣挖掘和冷启动优化(如利用用户设备中的非结构化数据)来补充传统行为数据的不足,扩大推荐覆盖面。

NDCG 的提升幅度较小,但 NDCG 的领先说明 PKGRec 在推荐列表的排序合理性上仍有改进。

为了进一步探讨预测阶段算法对结果的影响,比较了多层感知机预测、欧几里得内积预测以及混合预测三种策略。每种策略通过不同的方式计算用户与物品之间的相似度,生成最终的推荐评分。通过实验对比,能够深入了解不同预测算法对推荐性能的影响,实验结果如表 4 所示。由表可见,混合预测方法的 Precision, Recall 和 NDCG 等多个评价指标均表现出较好的推荐效果。具体地,混合预测能够在多个层次上捕捉用户与物品之间的潜在关系,提升了模型整体的预测精度和鲁棒性。因此,混合预测方法在推荐系统中的应用具有明显的优势,能够综合不同算法的优势,为实际应用中的个性化推荐任务提供更强的支持。

表 4 不同预测算法对结果的影响

Table 4 The impact of different prediction algorithms on the results

	Precision@10	Recall@10	NDCG@10
多层感知机	0.0615	0.0184	0.0637
欧几里得内积	0.0529	0.0158	0.0601
混合预测	0.0733	0.0216	0.0724

4 结论

本文研究了基于个人知识图谱的推荐系统,针对用户知识特征不充分表示问题提出一种新型的特征交互图神经网络模型 PKGRec,通过构建个人知识图谱和公共知识图谱的融合架构有效捕获用户个性化需求与物品特征之间的复杂关联。通过特征实体交互层对实体间的复杂交互进行建模,并设计偏好感知注意力机制来学习细粒度的用户表示。实验结果表明,与传统的推荐算法和

基于知识图谱的推荐方法相比,PKGRec模型在大规模真实世界数据集上的 *Precision*, *Recall* 和 *NDCG* 等指标都取得了显著的提升,特别是在处理冷启动和长尾推荐问题时表现出明显优势。

未来可以从三个方面拓展:首先,在模型架构方面,可以探索结合更先进的图神经网络拓扑结构与多头自适应注意力机制的融合策略,增强模型对用户-物品交互模式的隐含语义的理解能力;其次,在知识图谱融合方面,可以研究更高效的图谱对齐和融合方法,支持个人知识图谱的实时增量更新;最后,在实际应用中探索将个人知识图谱在不同的领域进行有效的迁移,实现跨域推荐,更全面地增强推荐系统。

参考文献

- [1] Burke R, Felfernig A, Göker M. Recommender systems: An overview. *AI Magazine*, 2011, 32(3): 13–18.
- [2] Ko H, Lee S, Park Y, et al. A survey of recommendation systems: Recommendation models, techniques, and application fields. *Electronics*, 2022, 11(1):141.
- [3] Roy D, Dutta M. A systematic review and research perspective on recommender systems. *Journal of Big Data*, 2022, 9(1):59.
- [4] Vullam N, Vellela S S, Venkateswara R B, et al. Multi-agent personalized recommendation system in e-commerce based on user//2023 2nd International Conference on Applied Artificial Intelligence and Computing. Salem, MA, USA: IEEE, 2023: 1194–1199.
- [5] Panda D K, Ray S. Approaches and algorithms to mitigate cold start problems in recommender systems: A systematic literature review. *Journal of Intelligent Information Systems*, 2022, 59(2): 341–366.
- [6] Wang Y, Liu Z W, Fan Z W, et al. DSKReG: Differentiable sampling on knowledge graph for recommendation with relational GNN//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York, NY, USA: Association for Computing Machinery, 2021:3513–3517.
- [7] Zhang M Q, Wu S, Yu X L, et al. Dynamic graph neural networks for sequential recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(5):4741–4753.
- [8] Zou X H. A survey on application of knowledge graph. *Journal of Physics Conference Series*, 2020, 1487(1):012016.
- [9] Balog K, Kenter T. Personal knowledge graphs: A research agenda//Proceedings of the ACM SIGIR International Conference on the Theory of Information Retrieval. Santa Clara, CA, USA: ICTIR, 2019:219–220.
- [10] Yen A Z, Huang H H, Chen H H. Ten questions in lifelog mining and information recall//Proceedings of 2021 International Conference on Multimedia Retrieval. New York, NY, USA: Association for Computing Machinery, 2021:511–518.
- [11] Chakraborty P, Dutta S, Sanyal D K. Personal research knowledge graphs//Companion Proceedings of the Web Conference 2022. New York, NY, USA: Association for Computing Machinery, 2022: 763–768.
- [12] Yang Y H, Huang C, Xia L H, et al. Knowledge graph self-supervised rationalization for recommendation//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2023:3046–3056.
- [13] Zhang J C, Zain A M, Zhou K Q, et al. A review of recommender systems based on knowledge graph embedding. *Expert Systems with Applications*, 2024, 250:123876.
- [14] Jin J R, Qin J R, Fang Y C, et al. An efficient neighborhood-based interaction model for recommendation on heterogeneous graph//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, NY, USA: Association for Computing Machinery, 2020:75–84.
- [15] Shi D Q, Wang T, Xing H, et al. A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning. *Knowledge-Based Systems*, 2020, 195:105618.
- [16] Li Q Y, Xia W, Yin L A, et al. Graph enhanced hierarchical reinforcement learning for goal-oriented

- learning path recommendation//Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. New York, NY, USA: Association for Computing Machinery, 2023: 1318—1327.
- [17] Wang X, He X N, Wang M, et al. Neural graph collaborative filtering//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2019: 165—174.
- [18] Wang Z, Lin G Y, Tan H B, 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. New York, NY, USA: Association for Computing Machinery, 2020: 219—228.
- [19] Wang X, Huang T L, Wang D X, et al. Learning intents behind interactions with knowledge graph for recommendation//Proceedings of the Web Conference 2021. New York, NY, USA: Association for Computing Machinery, 2021: 878—887.
- [20] Tang G, Gan X Y, Wang J H, et al. EditKG: Editing knowledge graph for recommendation//Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2024: 112—122.
- [21] Yang Y H, Huang C, Xia L H, et al. Knowledge graph contrastive learning for recommendation//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2022: 1434—1443.
- [22] Yang Y, Lin J X, Zhang X L, et al. PKG: A personal knowledge graph for recommendation//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2022: 3334—3338.
- [23] Liang S, Shao J, Zhang J S, et al. Graph-based non-sampling for knowledge graph enhanced recommendation. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(9): 9462—9475.
- [24] Palumbo E, Rizzo G, Troncy R. Entity2rec: Learning user-item relatedness from knowledge graphs for top- n item recommendation//Proceedings of the 11th ACM Conference on Recommender Systems. New York, NY, USA: Association for Computing Machinery, 2017: 32—36.
- [25] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback. <https://arxiv.org/abs/1205.2618>, 2012—05—09.
- [26] He X N, Chua T S. Neural factorization machines for sparse predictive analytics//Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, NY, USA: Association for Computing Machinery, 2017: 355—364.
- [27] Zhang F Z, Yuan N J, Lian D F, et al. Collaborative knowledge base embedding for recommender systems//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, NY, USA: Association for Computing Machinery, 2016: 353—362.
- [28] Zhang Y H, Wang J, Luo J. Knowledge graph embedding based collaborative filtering. IEEE Access, 2020(8): 134553—134562.
- [29] Wang X, He X N, Cao Y X, et al. KGAT: Knowledge graph attention network for recommendation//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, NY, USA: Association for Computing Machinery, 2019: 950—958.

(责任编辑 杨可盛)