

融合协同知识图谱和图卷积网络的推荐算法

沈鑫科^{1,2}, 李 勇^{1,2}, 陈建伟², 陈囿任¹

(1. 新疆师范大学 计算机科学技术学院, 新疆 乌鲁木齐 830054;

2. 新疆电子研究所, 新疆 乌鲁木齐 830013)

摘要:推荐系统广泛应用于互联网,缓解信息过载问题。现有研究通常将知识图谱引入推荐算法中,但不能有效获取用户与项目的高阶建模以及存在数据稀疏性的问题。该文提出了一种融合协同知识图谱和图卷积网络的推荐算法(CKGCN)。首先,将用户-项目交互矩阵与项目知识图谱构建为协同知识图谱,利用知识感知注意力机制对邻居节点进行权重分配,递归地捕获用户和项目的特征向量,搜索用户对项目的潜在喜好,有效缓解数据稀疏性的问题。其次,采用基于图卷积网络的邻域聚合算法捕捉每层实体网络之间的高阶联系,将实体与邻域实体聚合,丰富实体语义表示。另外,通过交叉压缩单元协作处理项目特征向量与实体特征向量,探索二者的高阶特征交互,从而过滤实体的冗余信息,挖掘项目更深层次的关系。最后,对用户特征向量与项目特征向量进行计算得出用户对项目的预测概率。经过点击率预测及Top-k推荐实验证明,在书籍Book_Crossing和音乐Last.FM两个公开的数据集上,该算法与五种基线算法相比较,AUC,ACC,F1,Recall@k和Precision@k评价指标值均有提升,表明该模型具有良好的推荐性能。

关键词:推荐算法;协同知识图谱;注意力机制;图卷积网络;实体特征

中图分类号:TP391.1

文献标识码:A

文章编号:1673-629X(2024)01-0150-08

doi:10.3969/j.issn.1673-629X.2024.01.022

Collaborative Knowledge Graph and Graph Convolution Network Based Recommendation Algorithm

SHEN Xin-ke^{1,2}, LI Yong^{1,2}, CHEN Jian-wei², CHEN You-ren¹

(1. School of Computer Science and Technology, Xinjiang Normal University, Urumqi 830054, China;

2. Xinjiang Electronic Research Institute, Urumqi 830013, China)

Abstract:The recommendation system is widely used in the Internet to alleviate the problem of information overload. The existing research usually introduces knowledge graph into recommendation algorithm, but it cannot effectively obtain the high-level modeling of users and projects and has the problem of data sparsity. We propose a collaborative knowledge graph and graph convolution network based recommendation algorithm (CKGCN). Firstly, the user project interaction matrix and the project knowledge graph are constructed as a collaborative knowledge graph. The weight of neighbor nodes is allocated using the knowledge awareness attention mechanism, the feature vectors of users and projects are captured recursively, and the potential preferences of users for projects are searched to effectively alleviate the problem of data sparsity. Secondly, the neighborhood aggregation algorithm based on graph convolution network is used to capture the higher-order relationship between each layer of entity network, aggregate entities and neighborhood entities, and enrich entity semantic representation. In addition, the cross-compression unit cooperatively processes the project feature vector and entity feature vector to explore their higher-order feature interaction, so as to filter the redundant information of entities and mine the deeper relationship of projects. Finally, the user feature vector and the project feature vector are calculated to obtain the prediction probability of the user to the project. According to the hit rate prediction and Top-k recommendation experiment, on the two public datasets of Crossing and Music Last. FM, this model is compared with five baseline models, namely, AUC, ACC, F1 Recall@k and Precision@k, and the evaluation index values have been improved, indicating that the model has good recommendation performance.

Key words: recommendation algorithm; collaborative knowledge graph; attention mechanism; graph convolution network; entity feature

收稿日期:2023-02-06

修回日期:2023-06-07

基金项目:新疆自治区重点研发计划项目(2022B01007-3);国家自然科学基金项目(62241209)

作者简介:沈鑫科(1999-),男,硕士研究生,CCF会员(I8181G),研究方向为知识图谱与智能系统;通讯作者:李 勇(1983-),男,副教授,博士,硕导,CCF专业会员(20976M),研究方向为机器学习与软件工程。

0 引言

随着互联网的高速发展,用户难以在繁杂的信息中找出真正感兴趣的内容,存在着严重的信息过载问题^[1]。为了解决该问题,将推荐系统应用于互联网领域,以满足用户的个性化兴趣并减轻信息过载问题。在传统的推荐算法中,通过分析用户的历史行为进行推荐的协同过滤算法得到了广泛应用,但通常面临冷启动、稀疏性等问题^[2]。为了解决上述问题,研究人员普遍将辅助信息加入推荐系统,例如社交网络^[3]、图片^[4]、属性^[5]和项目^[6]等,以此提升推荐效果。知识图谱(Knowledge Graph, KG)中实体与实体间蕴含着丰富的语义信息,有利于拓展实体之间的潜在联系。实体与实体之间的多种关系也有利于关联用户的潜在兴趣。将知识图谱引入推荐系统已经取得了显著的研究与应用成果^[7]。

知识图谱是由形如头实体、关系和尾实体的三元组构成的异构有向图^[8]。知识图谱通过项目与属性的映射可以更好地理解项目之间的关系;通过不同类型的关系连接实体,进而捕获实体之间的语义相关性^[9]。与传统的基于协同过滤的推荐系统相比,基于知识图谱的推荐系统在推荐性能和可解释性方面要表现得优秀。

文献[10]提出知识图注意力网络(KGAT),将用户-项目交互矩阵与知识图谱融合为协同知识图谱(Collaborative Knowledge Group, CKG)以缓解数据的稀疏性。文献[11]提出一种多任务推荐框架(MKR),通过多任务学习自动共享实体的高阶特征,学习实体之间的潜在隐藏关系。文献[12]提出知识图卷积网络模型(KGCN),利用图卷积网络,以知识图谱为单位的邻居之间的传播来计算项目的嵌入。

以上方法虽然通过知识图谱提高了推荐系统的性能,但未能充分利用知识图谱捕捉用户-项目之间的高阶关系,只考虑了用户与项目或者实体与实体之间的联系。针对以上问题,该文提出了一种融合协同知识图谱与图卷积网络的混合推荐模型(Collaborative Knowledge Graph and Graph Convolution Network Based Recommendation Algorithm, CKGCN)。主要贡献如下:

(1)将用户-项目交互图与项目知识图谱相融合,构成协同知识图谱,使用知识感知注意力机制嵌入传播得到用户和项目的特征表示。

(2)利用KGCN中邻域聚合的思想,对协同知识图谱中的实体进行模型构建,将获得的每一层实体特征表示与项目特征表示通过交互单元进行优化,提高用户与项目的高阶关系。

(3)在Book_Crossing和Last.FM两个公开的数

据集上进行点击率预测(CTR)和Top-k推荐实验,实验效果与基线模型相比均有提升。

1 相关工作

1.1 基于知识图谱的推荐系统

现有的基于知识图谱的推荐系统可以分成三类:基于嵌入的方法、基于路径的方法和混合方法。

(1)基于嵌入的方法使用知识图嵌入进行预训练得到的实体嵌入来扩充用户和项目表征的语义信息。文献[13]提出一种深度知识感知网络(DKN),设计了包含上下文信息的实体嵌入,然后通过CNN框架进行新闻推荐。文献[14]提出一种知识增强的序列化推荐系统(KSR),采用TransE方法将实体转化为嵌入向量,加权求和后得到用户的细粒度兴趣表示。文献[15]提出一种协同知识库嵌入模型(CKE),从实体嵌入、文本嵌入和视觉嵌入提取语义信息,丰富知识库,提高推荐效果。此类方法更侧重于建模严格的语义相关性,这更适合于图应用而不是推荐。

(2)基于路径的方法中,知识图谱中丰富的实体存在多条路径。文献[16]提出一种个性化实体推荐系统(PER),提取用户之间不同元路径潜在特征,构建异构信息网络,加深用户与项目的连接性。文献[17]提出一种知识引导的成对重构网络(KPRN),自动提取连接用户-项目对的路径,然后通过循环神经网络对这些路径进行建模以进行用户偏好建模。此类方法高度依赖于元路径的设计,这在实践中很难进行优化。

(3)混合方法融合以上两种方法。文献[18]提出RippleNet模型,融合基于嵌入和基于路径的方法,采用水滴波纹思想在知识图谱中传播用户每层的潜在偏好,并将其组合得到用户特征表示。文献[19]提出一种自适应自注意力模型(AKUPM),对实体通过自注意力机制分配适当的权重,学习实体对用户的相关性来捕获实体特征。但是此类方法通常伴随着较高的计算和存储成本。

上述文献在一定程度上缓解了数据稀疏性与冷启动问题,但并没有充分将知识图谱的图结构信息细化实体向量表示。随着图卷积网络在各领域的深入研究,其对节点的特征与结构信息的处理为基于知识图谱的推荐算法提供了新的思路。

1.2 基于图卷积网络的推荐系统

基于图卷积网络的推荐算法使用神经网络从节点的本地网络邻域聚合节点特征信息。KGCN模型开创性地采用GCN层来聚合知识图谱中的实体以推断项目嵌入。为提高KGCN的鲁棒性,文献[20]假设知识图谱中的相邻项目可能具有相似的用户相关性标签,提供了对相邻项目边权重的正则化。文献[21]通过

引入用户偏好网络,加深图卷积网络对节点的特征提取。

基于以上分析,该文提出了融合协同知识图谱和图卷积网络的推荐算法,一方面引入图卷积网络细化实体向量表示,捕捉用户-项目间的高阶联系。另一方面,使用注意力嵌入传播减少实体噪声污染。

2 CKGCN 模型

该文将用户-项目交互图与项目知识图谱结合为

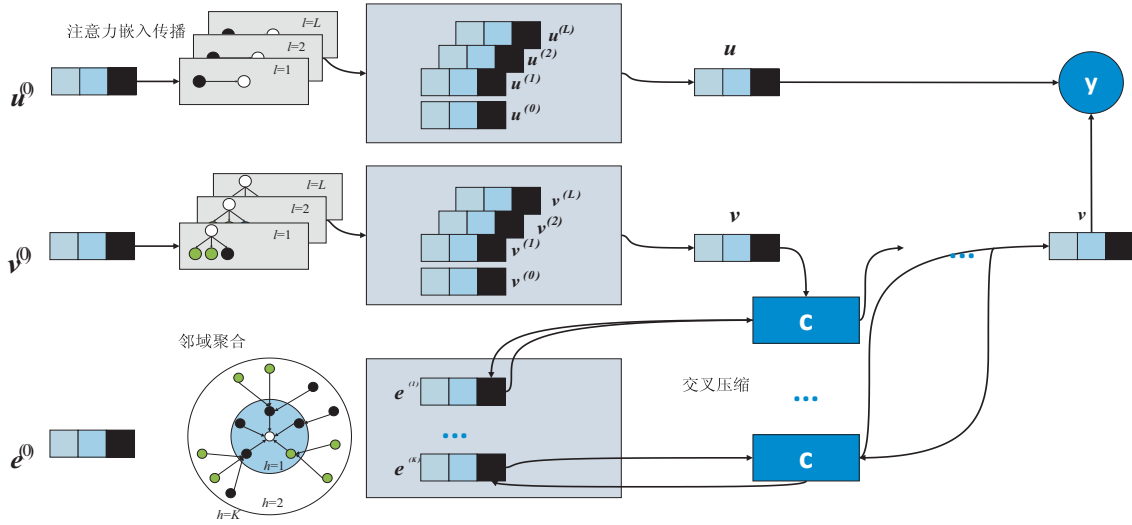


图 1 CKGCN 模型

2.1 问题定义

在一个推荐任务中,设 $U = \{u_1, u_2, \dots, u_m\}$ 为 m 个用户的集合, $V = \{v_1, v_2, \dots, v_n\}$ 为 n 个项目的集合, $Y = \{y_{uv} | u \in U, v \in V\}$ 为用户-项目交互矩阵。 y_{uv} 表示用户 u 与项目 v 是否交互记录(比如评分、收藏、购买等行为),如式 1 所示。

$$y_{uv} = \begin{cases} 1, & u \text{ 对 } v \text{ 有交互记录} \\ 0, & u \text{ 对 } v \text{ 没有交互记录} \end{cases} \quad (1)$$

知识图谱 G 由若干个实体和关系组成的三元组 (h, r, t) 构成, $h \in E, r \in R$ 和 $t \in E$ 分别表示为头实体、关系和尾实体, E 和 R 代表 G 中实体和关系的集合。用户项目交互矩阵中与知识图谱结合可以生成协同知识图谱。用户和项目可以视为新的实体,是否有过交互记录可以视为新的关系。

给定协同知识图谱后,预测用户是否对其之前未交互过的项目感兴趣。最终模型学习预测函数— $\hat{y}_{uv} = F(u, v; \theta)$, 其中 \hat{y}_{uv} 是 u 与 v 感兴趣概率, θ 是训练参数。

2.2 基于注意力嵌入传播的实体特征提取

对于协同知识图谱嵌入,该文采用 TransR^[17] 方法。TransR 旨在执行知识图谱中实体之间的链接预测,通过在不同的空间中对实体和关系进行建模,拓展

协同知识图谱嵌入到注意力嵌入传播模块,获得用户向量 u 与项目向量 v ,再将实体和关系嵌入到优化的图卷积网络中,通过邻域聚合的方法聚合实体周边邻居得到实体向量 $e^{(k)}$,对于每次聚合的实体向量 $e^{(k)}$ 与项目向量 v 进行交互处理得到最终的项目向量。最后,将用户向量 u 与项目向量 v 进行计算得到最终预测概率 y ,如图 1 所示。

了建模的灵活性。对于协同知识图谱中的三元组 (h, r, t) ,基于优化翻译原理 $e_h^r + e_r \approx e_t^r$ 来嵌入每个实体和关系。 e_h^r 和 e_t^r 是头实体和尾实体在关系 r 上的投影表示。接下来,对于给定的三元组 (h, r, t) ,其得分公式如式 2 所示。

$$g(h, r, t) = \|W_r e_h + e_r - W_r e_t\|_2^2 \quad (2)$$

其中, $W_r \in \mathbb{R}^{d \times d}$ 是关系 r 的变换矩阵,它将实体从 d 维实体空间投影到 k 维关系空间上。 $g(h, r, t)$ 的分数越低,表明三元组更加嵌入效果更加真实。

对于实体 h ,使用 $N_h = \{(h, r, t) | (h, r, t) \in \text{CKG}\}$ 来表示三元组,计算 h 的周边实体网络的线性组合 e_{N_h} ,如式 3 所示。

$$e_{N_h} = \sum_{(h, r, t) \in N_h} \pi(h, r, t) e_t \quad (3)$$

通过关系注意力机制实现 $\pi(h, r, t)$,如式 4 所示。

$$\pi(h, r, t) = (W_r e_t)^T \text{sigmoid}(W_r e_h + e_r) \quad (4)$$

其中, T 为转置操作。接下来,对所有与 h 相连的三元组的注意力得分进行归一化操作,如式 5 所示。

$$\pi(h, r, t) = \frac{\exp(\pi(h, r, t))}{\sum_{(h, r, t) \in N_h} \exp(\pi(h, r, t))} \quad (5)$$

最终的注意力得分能判断应该对哪些邻居节点给予更多的关注以捕获关联信息。

最后将实体 e_h 以及周边实体网络 e_{N_h} 聚合成新的实体 h , $e_h = f(e_h, e_{N_h})$, f 如式 6 所示。

$$f = \text{LeakyReLU}(\mathbf{W}(e_h + e_{N_h})) \quad (6)$$

其中, $\mathbf{W} \in \mathbb{R}^{d \times d}$ 是可训练的权重矩阵。

为了探究深层次的语义信息,可以进一步地递归更多传播层并调整传播距离。在第 l 层中,将实体递归表示,如式 7 和式 8 所示。

$$e_h^{(l)} = f(e_h^{(l-1)}, e_{N_h}^{(l-1)}) \quad (7)$$

$$e_{N_h}^{(l-1)} = \sum_{(h,r,t) \in N_h} \pi(h,r,t) e_t^{(l-1)} \quad (8)$$

执行 l 层后,得到用户节点 u 的多个表示,即 $\{e_u^{(1)}, \dots, e_u^{(l)}\}$; 与用户节点类似可以得到项目节点 v 的多个表示,即 $\{e_v^{(1)}, \dots, e_v^{(l)}\}$, 将每一层的节点拼接得到用户表示和初步的项目表示,如式 9 所示。

$$u = e_u^{(0)} \parallel e_u^{(1)} \parallel \dots \parallel e_u^{(l)}, v = e_v^{(0)} \parallel e_v^{(1)} \parallel \dots \parallel e_v^{(l)} \quad (9)$$

特别注意的是,对于项目表示要多进行邻域聚合操作来增强它的表达能力。

2.3 基于邻域聚合的实体特征提取

该文采用 KGCCN^[12] 算法中的邻域聚合方法,利用图卷积技术将知识图谱中实体的邻域信息聚合,从而丰富实体的语义表示。

首先,用 $M(v)$ 表示直接连接到 v 的实体,用特定的关系评分函数代表用户对不同关系的重视程度,如式 10 所示。

$$\pi_{r,v}^u = u \cdot r \quad (10)$$

为了获取实体 v 的临近拓扑结构,计算与实体直接相连的节点的线性组合,如式 11 所示。

$$v_{M(v)}^u = \sum_{e \in M(v)} \pi_{r,v}^u e \quad (11)$$

其中, $\pi_{r,v}^u$ 是归一化的用户关系得分,如式 12 所示。

$$\pi_{r,v}^u = \frac{\exp(\pi_{r,v}^u)}{\sum_{e \in M(v)} \exp(\pi_{r,v}^u)} \quad (12)$$

在计算实体的邻域表示时,用户关系得分充当个性化过滤器,用于聚焦用户感兴趣的邻居实体。在真实世界的知识图谱中, $M(e)$ 的大小在不同实体上有不同的数据。为了使每个批处理的计算过程更加合理,获取实体邻居时取用固定的数目。对实体 v 的邻域表示为 $v_{S(v)}^u$, 其中, $S(v) \subseteq M(v)$ 且 $|S(v)| = N$, N 为预设置的邻居常数。

针对第 K 跳邻域聚合层,利用聚合器将初始的项目表示 e_u^{K-1} 及其邻域表示 $e_u^K = v_{S(v)}^u$ 进行聚合操作,获取融合了邻域信息的项目表示 e_u^K , 如式 13 所示。

$$e_u^K = \text{ReLU}(\mathbf{W} \cdot (e_u^K + e_u^{K-1}) + b) \quad (13)$$

其中, $\mathbf{W} \in \mathbb{R}^{d \times d}$ 和 $b \in \mathbb{R}^d$ 分别表示可训练的权重和偏置。

为了减少项目向量的拟合噪声,通过交叉压缩单元建模注意力嵌入传播得到的项目向量 v 和每一层的邻域聚合 e_u^K 的实体表示,如图 2 所示。




图 2 交叉压缩单元

对于项目向量 v 和它关联的实体的第 K 层邻域聚合表示 e_u^K 进行交叉操作,构造交叉矩阵 C_K , 如式 14 所示。

$$C_K = v e_u^K = \begin{bmatrix} v^{(1)} e_u^{K(1)} & \dots & v^{(1)} e_u^{K(d)} \\ \vdots & \ddots & \vdots \\ v^{(d)} e_u^{K(1)} & \dots & v^{(d)} e_u^{K(d)} \end{bmatrix} \quad (14)$$

将交叉矩阵从 $d \times d$ 的向量空间压缩得到更新后的 d 维向量 v 和 e_u^K , 即新的特征表示,如式 15 所示。

$$\begin{aligned} v &= C_K w_K^{VV} + C_K^T w_K^{VV} + b_K^V = v e_u^{KT} w_K^{VV} + e_u^K v^T w_K^{VE} + b_K^V \\ e_u^K &= C_K w_K^{VE} + C_K^T w_K^{EE} + b_K^E = v e_u^{KT} w_K^{VE} + e_u^K v^T w_K^{EE} + b_K^E \end{aligned} \quad (15)$$

其中, $w_K \in \mathbb{R}^d$ 和 $b_K \in \mathbb{R}^d$ 是可训练的权重和偏置。

最后把用户特征表示与经过交叉压缩得到的项目特征表示计算预测概率,如式 16 所示。

$$\hat{y}_{uv} = \sigma(u^T v) \quad (16)$$

其中, σ 函数为 sigmoid 函数。

2.4 模型优化

为了尽可能提高 CKGCN 的推荐性能,完整的损失函数包含交叉熵损失函数、协同知识图谱嵌入损失函数和正则化项,如式 17 所示。

$$\begin{aligned} L &= L_{RS} + L_{KGE} + \lambda \|\mathbf{W}\|_2^2 = \sum_{(u,v) \in Y} j(\hat{y}_{uv}, y_{uv}) + \\ &\quad \sum_{(h,r,t,t') \in H} -\ln \sigma(g(h,r,t') - g(h,r,t)) + \\ &\quad \lambda \|\mathbf{W}\|_2^2 \end{aligned} \quad (17)$$

第一项 L_{RS} 为预测值 \hat{y}_{uv} 和真实值 y_{uv} 之间的损失值, j 为交叉熵损失函数。第二项 L_{KGE} 为协同知识图谱嵌入损失值, g 见公式(2)。 H 为协同知识图谱, $H = \{(h,r,t,t') \mid (h,r,t) \in \text{CKG}, (h,r,t') \notin \text{CKG}\}$, 其中 (h,r,t') 是对协同知识图谱的负采样。第三项则是 L2 范数,防止过拟合。使用 Adam 算法对参数进行优化调整。

2.5 算法流程

CKGCN 模型的算法流程如算法 1 所示。

算法 1:CKGCN 算法

输入:用户-项目交互矩阵 \mathbf{Y} , 协同知识图谱 (CKG)

输出: \hat{y}_{uv} , 用户 u 点击物品 v 的概率

1. 初始化参数
2. FOR 训练迭代次数 DO
3. 在 batchsize 空间内对 \mathbf{Y} 和 CKG 进行负采样
4. FOR 层数 l 从 $1 \sim L$ DO
5. 按照公式 2~4 获得每一个三元组的注意力分数
6. 按照公式 7 和公式 8 获得用户和项目的递归嵌入表示 $\mathbf{e}_u^{(l)}, \mathbf{e}_v^{(l)}$
7. 将各层的嵌入表示按照公式 9 进行拼接获得新的用户嵌入表示 u 和项目嵌入表示 v
8. END FOR
9. FOR 跳数 k 从 $1 \sim K$ DO
10. 获取项目 v 在协同知识图谱 CKG 中的 k 跳实体集合 $M(v)$
11. 按照公式 10 获取用户 u 对不同关系的重视程度
12. 按照公式 11 获取 K 跳时实体嵌入表示 \mathbf{e}_u^K
13. 按照公式 13 进行聚合更新 \mathbf{e}_u^K
14. 将 \mathbf{e}_u^K 和 v 放入交叉压缩模块, 按照公式 14 和公式 15 获得新的 \mathbf{e}_u^K 和 v
15. END FOR
16. 按照公式 16 计算预测概率 \hat{y}_{uv}
17. 使用 Adam 算法更新参数
18. END FOR

算法 1 的具体过程如下:首先初始化所有参数,对输入的用户-项目交互矩阵和协同知识图谱进行负采样,然后通过注意力嵌入传播获得第 l 层传播的实体 $\mathbf{e}_u^{(l)}, \mathbf{e}_v^{(l)}$ (5~6 行),将每层的实体进行拼接得到用户嵌入表示 u 和项目嵌入表示 v (第 7 行);接着获取实体在协同知识图谱中的 K 邻域聚合表示 \mathbf{e}_u^K (9~12 行),将 \mathbf{e}_u^K 和 v 进行交叉压缩处理(第 13 行)。最后,预测用户 u 对项目 v 的兴趣(第 16 行)。

3 实验结果与分析

3.1 数据集

该文使用两个公开的数据集来测试模型的性能。Book_Crossing 是由德国自由堡大学制作的在书籍推荐中使用的数据集,其中包含了一百多万条用户对书籍的评分(0 到 10)。Last. FM 则记录了两千多名用户对不同音乐的聆听记录。该文在进行实验之前对数据进行预处理。两个数据集中,用户如果跟书籍或者音乐有交互记录,则将其视为正反馈记录,并随机抽取等量的没有交互记录的数据视为负反馈记录。两个数据集的基本数据信息如表 1 所示。

表 1 数据集的统计信息

数据集	Book_Crossing	Last. FM
用户数	17 860	1 872
项目数	14 910	3 846
交互数	139 746	42 346
三元组数	19 876	15 518
实体数	24 127	9 366
关系数	10	60

3.2 实验设置

该文设置两个数据集的训练、评估和测试集的比例为 6 : 2 : 2,超参数利用优化曲线下面积 (Area Under Curve, AUC) 获得。在以下两个场景中测试模型性能:

(1)CTR 预测。将测试数据应用在训练好的模型下进行点击预测,使用 AUC, ACC(准确率)和 F1 指标评估 CTR 预测性能。

(2)Top-k 推荐。通过训练好的模型为用户提供 k 个可能感兴趣的项目,使用 Precision@k 和 Recall@k 指标进行评估。

每个数据集的超参数设置如表 2 所示,其中 d , L , K 和 N 分别为嵌入维度、注意力嵌入传播层数、图卷积网络层数和图卷积邻居数, λ 为平衡参数, η 为学习率。

表 2 两个数据集的超参数设置

数据集	d	L	K	N	λ	η
Book_Crossing	64	2	3	8	0.000 02	0.000 2
Last. FM	16	2	1	8	0.000 01	0.000 5

3.3 对比方法

将提出的 CKGCN 模型与以下五种基线方法进行性能比较。

(1)CKE^[15]:通过引入知识图谱结构,文本,图像来提升推荐系统性能,分别采用 TransR, 栈式降噪自编码和栈式卷积自编码方法拼接提取语义表示。

(2)RippleNet^[19]:利用水滴波纹传播的思想,以用户感兴趣的物品为起点,在知识图谱中不断寻找用户的潜在兴趣,丰富用户的语义表示。

(3)MKR^[11]:提出一种多任务特征学习的端到端推荐框架,通过深度学习得到的实体向量与项目向量以交替学习的方式丰富项目的语义表示。

(4)KGCN^[12]:通过挖掘知识图谱上的相关属性,有效地获取实体间的相关性。在实体的邻居集合体中采用 GCN 思想计算实体的邻域信息,从而获取用户的潜在兴趣。

(5)KGAT^[10]:提出一种基于传播的推荐模型,将知识图谱和用户项目交互矩阵构建为协同知识图谱,

采用注意力机制对用户嵌入和项目嵌入训练传播期间的邻居权重。

3.4 性能比较

3.4.1 CTR 预测实验

CKGCN 与不同基线模型的 CTR 预测实验结果如表 3 所示,所选评价指标为 AUC,ACC,F1。

表 3 CTR 结果

模型	Book_Crossing			Last. FM		
	AUC	ACC	F1	AUC	ACC	F1
CKE	0.654	0.629	0.599	0.733	0.670	0.645
RippleNet	0.727	0.663	0.650	0.765	0.692	0.668
MKR	0.731	0.693	0.661	0.791	0.729	0.721
KGCN	0.701	0.654	0.671	0.792	0.711	0.683
KGAT	0.721	0.659	0.653	0.820	0.728	0.738
CKGCN	0.740	0.696	0.684	0.803	0.730	0.739

根据表 3 可以得出以下结论:

(1)在 Book_Crossing 数据集中,CKGCN 模型在 AUC 指标上与 MKR 相比提升了 1.23%,在 ACC 指标上与 MKR 相比提升了 0.43%,在 F1 指标上与 KGCN 相比提升了 1.94%。CKGCN 在 Book_Crossing 数据集中的推荐效果优于其他五种基线模型,证明了模型在捕获项目邻域信息和用户项目高阶关系后提升了推荐效果。

(2)在 Last. FM 数据集中,CKGCN 模型在 ACC 指标上与 MKR 相比提升了 0.14%,在 F1 指标上与

KGAT 相比提升了 0.14%。CKGCN 在 Last. FM 数据集中的推荐效果整体优于其他五种基线模型。但是在 AUC 指标上不如 KGAT,Last. FM 数据集比 Book_Crossing 数据集更为稀疏,说明注意力机制在处理稀疏场景下优势较为明显。在其他指标上,CKGCN 均优于 KGAT,说明聚合邻域信息的实体在经过交叉压缩单元后更能挖掘用户的潜在兴趣。

(3)KGCN 在 Last. FM 数据集上的表现要优于 MKR,充分证明了图卷积网络可以提高稀疏场景下的推荐效果。MKR 在 Book_Crossing 数据集上的表现要优于 KGCN,说明交叉压缩单元能改善稠密场景下的推荐效果。

3.4.2 Top-k 预测实验

CKGCN 与五种不同的基线模型进行了 Top-k 推荐实验,所选指标为 Recall@k 和 Precision@k, k 从 5 递增到 100。其中,Book_Crossing 数据集的实验结果如图 3(a)及图 3(b)所示;Last. FM 数据集的实验结果如图 3(c)及图 3(d)所示。通过观察得知,CKGCN 模型在整体性能上均优于其他基线模型。在 k 值大于 20 后,图卷积网络对实体特征进行了过度的聚合,融入了较多噪声,导致 CKGCN 模型的 Recall@k 与 Precision@k 下降。文中模型在 k 小于 20 的情况下均优于其他基线模型,说明 CKGCN 更侧重于为用户进行精确推荐。

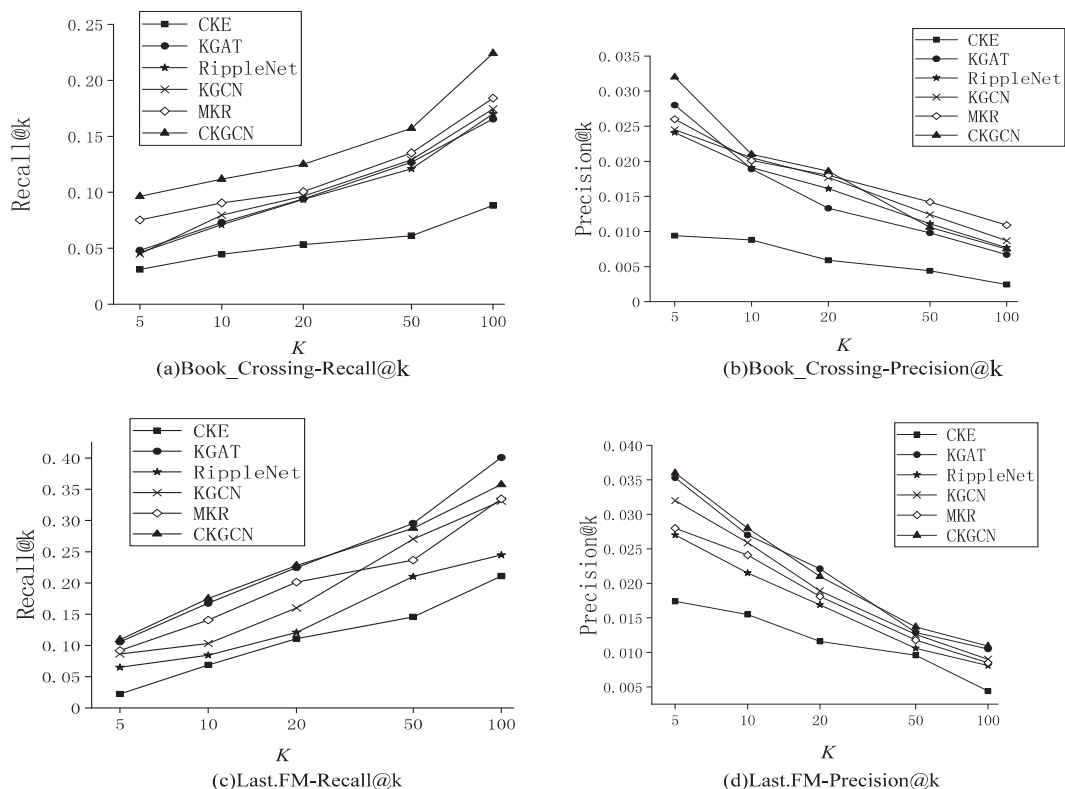


图 3 Top-k 推荐效果

3.5 消融实验

采用消融实验,通过移除或更改模块,进一步验证交叉压缩单元在改良后的邻域聚合中的有效性。本节实验设计了另外两种消融模型与 CKGCN 进行比较,以下为消融模型的介绍,实验结果如表 4 所示。

(1)CKGCN-n: 去除构建协同知识图谱的操作,只对项目 v 进行注意力嵌入传播,再与 e_u^k 传入交叉压缩单元后和用户 u 计算预测概率。

(2)CKGCN-s: 去除图卷积网络中聚合器的操作,将用户高阶表示 u 和项目高阶表示 v 经过交叉压缩操作后计算预测概率。

表 4 消融实验

模型	Book_Crossing			Last. FM		
	AUC	ACC	F1	AUC	ACC	F1
CKGCN	0.740	0.696	0.684	0.803	0.730	0.739
CKGCN-n	0.711	0.674	0.644	0.774	0.694	0.657
CKGCN-s	0.719	0.684	0.661	0.781	0.701	0.691

根据表 4 可得,CKGCN 在各项指标上均优于其他消融模型,说明协同知识图谱的加入让用户 u 与知识图谱中的实体相连,建立用户的高阶建模。此外图卷积网络的聚合效果让物品的语义表示更加具有代表性。

3.6 超参数分析

为了探究模型中参数对推荐性能的影响,本节实验测试邻域聚合中不同跳数 K 与注意力嵌入传播中不同邻居数 N 对 CKGCN 模型的影响,评价指标为 AUC,如表 5 和表 6 所示。

表 5 不同 K 的 AUC 值

数据集	1	2	3	4	5
Book_Crossing	0.711	0.729	0.740	0.731	0.704
Last. FM	0.803	0.786	0.775	0.732	0.719

表 6 不同 N 的 AUC 值

数据集	2	4	8	16	32
Book_Crossing	0.721	0.733	0.740	0.705	0.685
Last. FM	0.764	0.788	0.803	0.776	0.709

根据以上实验可得出以下结论:

(1)据表 5 可得,在稀疏场景下, K 为 1 层时模型的性能最好,而相对稠密的 Book_Crossing 数据集中, K 为 3 层时模型的效果最好。说明稀疏场景下模型从远距离聚合邻域信息时带来了更大的噪声。

(2)据表 6 可得,取邻居数 $N = 8$ 的情况下,CKGCN 模型在两种数据集下都达到了最佳的推荐性能。随着聚合邻域信息的邻居数增加,模型的推荐效果均呈现出先升后降的趋势,说明较小的邻居数没有

足够能力来聚合邻域信息,而较大的邻居数也将导致邻域信息被噪声污染。

4 结束语

针对用户-项目的高阶项目难以捕捉及数据稀疏性的问题,该文提出一种融合协同知识图谱和图卷积网络的混合推荐算法(CKGCN)。CKGCN 通过构建协同知识图谱缓解数据的稀疏性,通过注意力嵌入传播和邻域聚合获取项目表示,在交叉压缩单元中进行优化获取高阶项目表示,从而提高推荐性能。在两个数据集中与五种基线模型进行对比,在整体上均处于领先地位。该文并未考虑用户兴趣随时间的变化对模型的影响,这将是未来工作的研究重点。

参考文献:

- [1] ZHANG F Z, NICHOLAS J Y, LIAND F, et al. Collaborative knowledge base embedding for recommender systems [C]//Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco: ACM, 2016: 353-362.
- [2] KARABADJI N E I, BELDJOUDE S, SERIDI-BOUCH-ELAGHEM H, et al. Improving memory-based user collaborative filtering with evolutionary multi-objective optimization [J]. Expert Systems with Application, 2018, 98 (May): 153-165.
- [3] 黄立威, 江碧涛, 吕守业, 等. 基于深度学习的推荐系统研究综述 [J]. 计算机学报, 2018, 41 (7): 1619-1647.
- [4] 秦川, 祝恒书, 庄福振, 等. 基于知识图谱的推荐系统研究综述 [J]. 中国科学: 信息科学, 2020, 50 (7): 937-956.
- [5] 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 & data mining. London: ACM, 2018: 974-983.
- [6] 韩立峰, 陈莉. 融合用户属性与项目流行度的用户冷启动推荐模型 [J]. 计算机科学, 2021, 48 (2): 114-120.
- [7] SUN Z, YANG J, ZHANG J, et al. Recurrent knowledge graph embedding for effective recommendation [C]//Proceedings of the 12th ACM conference on recommender systems. Vancouver: ACM, 2018: 297-305.
- [8] JI S, PAN S, CAMBRIA E, et al. A survey on knowledge graphs: representation, acquisition, and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33 (2): 494-514.
- [9] CHEN X, XU H, ZHANG Y, et al. Sequential recommendation with user memory networks [C]//Web search and data mining. Marina Del Rey: ACM, 2018: 108-116.
- [10] WANG H, ZHANG F, ZHAO M, et al. Multi-task feature learning for knowledge graph enhanced recommendation

- [C]//The world wide web conference. San Francisco; ACM,2019;2000–2010.
- [11] 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 & data mining. Anchorage; ACM,2019;950–958.
- [12] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [C]//The world wide web conference. San Francisco; ACM, 2019; 3307 – 3313.
- [13] 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. Lyon; ACM,2018; 1835–1844.
- [14] HUANG J, ZHAO W X, DOU H, et al. Improving sequential recommendation with knowledge – enhanced memory networks [C]//The 41st international ACM SIGIR conference on research & development in information retrieval. Ann Arbor; ACM,2018;505–514.
- [15] 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. San Francisco; ACM,2016;353–362.
- [16] YU X, REN X, SUN Y, et al. Personalized entity recommendation: a heterogeneous information network approach [C]//Proceedings of the 7th ACM international conference on web search and data mining. New York; ACM,2014;283–292.
- [17] LIU X, LI L, WANG S, et al. Knowledge – guided pairwise reconstruction network for weakly supervised referring expression grounding [C]//Proceedings of the 27th ACM international conference on multimedia. Nice; ACM,2019;539–547.
- [18] 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. Torino; ACM,2018;417–426.
- [19] TANG X, WANG T, YANG H, et al. AKUPM: attention-enhanced knowledge-aware user preference model for recommendation [C]//Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining. Anchorage; ACM,2019;1891–1899.
- [20] 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 & data mining. Anchorage; ACM,2019;968–977.
- [21] 胡婷婷, 黄刚, 吴长旺. 融合知识图卷积网络的双端邻居推荐算法 [J]. 计算机技术与发展, 2022, 32(10): 34–40.