

# 融合知识图谱和轻量图卷积网络的推荐算法<sup>①</sup>



樊海玮, 张丽苗, 鲁芯丝雨, 王 帅

(长安大学 信息工程学院, 西安 710064)  
通信作者: 张丽苗, E-mail: [346371539@qq.com](mailto:346371539@qq.com)

**摘 要:** 针对知识图谱推荐算法用户端和项目端建模程度不均且模型复杂度较高等问题, 提出融合知识图谱和轻量图卷积网络的推荐算法. 在用户端, 利用用户相似性生成邻居集合, 将用户及其相似用户的交互记录在知识图谱上多次迭代传播, 增强用户特征表示. 在项目端, 将知识图谱中实体嵌入传播, 挖掘与用户喜好相关的项目信息; 接着, 利用轻量图卷积网络聚合邻域特征获得用户和项目的特征表示, 同时采用注意力机制将邻域权重融入实体, 增强节点的嵌入表示; 最后, 预测用户和项目之间的评分. 实验表明, 在 Book-Crossing 数据集上, 相较于最优基线,  $AUC$  和  $ACC$  分别提高了 1.8% 和 2.3%. 在 Yelp2018 数据集上,  $AUC$  和  $ACC$  分别提高了 1.2% 和 1.4%. 结果证明, 该模型与其他基准模型相比有较好的推荐性能.

**关键词:** 知识图谱; 图卷积网络; 注意力机制; 推荐算法

引用格式: 樊海玮, 张丽苗, 鲁芯丝雨, 王帅. 融合知识图谱和轻量图卷积网络的推荐算法. 计算机系统应用, 2023, 32(8): 207–213. <http://www.c-s-a.org.cn/1003-3254/9209.html>

## Recommendation Algorithm Integrating Knowledge Graph and Lightweight Graph Convolutional Network

FAN Hai-Wei, ZHANG Li-Miao, LU Xin-Si-Yu, WANG Shuai

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

**Abstract:** Given the uneven modeling degree between the user and project sides of the recommendation algorithms for knowledge graphs as well as high model complexity, a recommendation algorithm that integrates knowledge graph and lightweight graph convolutional network is proposed. On the user side, neighbor sets are generated based on user similarity, and the interaction records of users and their similar users are iteratively propagated on the knowledge graph for many times to enhance the representation of user features. On the project side, the entity on the knowledge graph is embedded and propagated to mine the project information related to user preferences. Then, the lightweight graph convolutional network is adopted to aggregate neighborhood features to obtain the feature representations of users and projects. At the same time, the attention mechanism is employed to incorporate neighborhood weights into the entities to enhance node embedding representation. Finally, the ratings between the user and the project are predicted. Experiments show that on the Book-Crossing dataset, compared with the optimal baseline,  $AUC$  and  $ACC$  are improved by 1.8% and 2.3%, respectively. On the Yelp2018 dataset,  $AUC$  and  $ACC$  are improved by 1.2% and 1.4%, respectively. The results demonstrate that the proposed model has better recommendation performance compared with other benchmark models.

**Key words:** knowledge graph (KG); graph convolutional network (GCN); attention mechanism; recommendation algorithm

① 基金项目: 陕西高等教育教学改革研究项目 (21BY031)

收稿时间: 2023-01-12; 修改时间: 2023-03-08; 采用时间: 2023-03-23; csa 在线出版时间: 2023-05-22

CNKI 网络首发时间: 2023-05-24

基于知识图谱的推荐算法早期多通过知识图谱嵌入<sup>[1]</sup>以增强项目表示,降低了知识图谱的高维性和异构性,但忽视了实体间的连通性.随后众多学者使用元路径丰富用户项目间的交互,提升了推荐结果的可解释性,但元路径需要手动设计<sup>[2]</sup>.这些方法虽然提高了推荐的准确性和推荐结果的可解释性<sup>[3]</sup>,但存在泛化能力差、性能不稳定<sup>[4]</sup>等问题.图卷积网络(graph convolutional network, GCN)在图结构数据上具有良好的信息提取和表示能力,逐步成为推荐系统中的研究热点<sup>[5,6]</sup>,其强大的信息传播能力能够挖掘实体间的高阶语义关系<sup>[7]</sup>,提升模型表达能力.然而,引入图卷积网络的推荐算法仍存在模型复杂度高,项目端和用户端建模程度不平衡等问题.

因此,论文构建 KLGC (knowledge graph and light graph convolution) 模型.在用户端引入用户邻居集合以增强用户特征表示;采用轻量图卷积网络<sup>[8]</sup>捕获实体间的高阶关系,简化标准 GCN 中非线性激活和特征转换模块,用于降低模型复杂度.在数据集 Book-Crossing 和 Yelp2018 上完成对比实验,验证了该模型的有效性.

## 1 相关研究

基于知识图谱的推荐方法可以分为:基于嵌入的方法、基于路径的方法和混合方法<sup>[9]</sup>.基于嵌入的方法主要包括 Trans 系列算法<sup>[10,11]</sup>,此类方法多应用于知识图谱补全和链路预测等任务,然而在推荐任务中性能表现较差.基于路径的方法关注实体间的联系,利用图谱中实体的连接模式完成推荐. Hu 等<sup>[12]</sup>使用卷积神经网络和元路径获得用户和项目的向量表示.此类方法依赖于手动设计元路径,应用于不同场景时缺乏可伸缩性.基于嵌入的方法主要学习知识图谱中的语义信息,基于路径的方法主要关注实体间的连接关系,都未充分利用知识图谱中蕴含的信息.因此,学者们开始尝试混合多种算法提升推荐效果. Wang 等<sup>[13]</sup>将基于嵌入的方法和基于路径的方法结合提出 RippleNet 模型,以用户的历史兴趣为基础沿着知识图谱中的路径传播,捕捉用户的偏好信息,增强用户特征表示.这种方法忽视了实体间关系的重要性、存在计算冗余的问题,难以保证推荐质量.

知识图谱以图结构的形式展示实体和关系,图卷积网络可以有效整合知识图谱结构特征,学习项目间语义关系和用户潜在偏好<sup>[14]</sup>.文献<sup>[15]</sup>融合知识图谱

和图卷积网络提出 KGCN 模型,采用 GCN 有偏差地聚合实体表示,并利用知识图谱中高阶链接在项目端聚合项目的属性信息,丰富了项目端的特征表示,然而,该模型没有考虑用户端的用户属性信息.针对这个问题,文献<sup>[16]</sup>在 KGCN 基础上提出了 DEKGCN 模型,在用户端添加辅助信息,使用图卷积网络分别聚合用户端和项目端的属性信息,从而提高了推荐性能.但是该模型在聚合用户信息时,使用人口统计学信息来构建用户属性图,用户端嵌入表示时语义丰富度较低.

上述融合知识图谱和图卷积网络的推荐方法利用了实体嵌入和高阶连接信息,但在信息传播过程中侧重于优化更新用户端或项目端一端的表示,对用户端和项目端建模程度不均,且采用了标准的图卷积网络模型,使得模型相对复杂.因此,本文基于 KGCN 提出 KLGC 模型,对用户和项目双端建模,在用户端引入用户邻居集合增强用户特征,采用轻量图卷积网络分别聚合用户端和项目端信息以提高推荐性能.

## 2 KLGC 模型

KLGC 模型的总体框架如图 1 所示.用户表征计算过程,以用户-项目交互矩阵和知识图谱作为输入,将用户浏览记录作为种子集在知识图谱中传播,获取用户偏好信息,使用轻量聚合器聚合得到用户嵌入表示.项目表征计算过程,以用户嵌入表示和知识图谱作为输入,使用注意力机制获取目标用户  $u$  与知识图谱三元组中各关系的影响权重,有选择地聚合邻域信息得到项目嵌入表示.最后,基于用户嵌入表示和项目嵌入表示计算交互概率.

在推荐模型中,用户集合和项目集合分别设置为  $U = \{u_1, u_2, \dots, u_m\}$ ,  $I = \{i_1, i_2, \dots, i_n\}$ , 用户-项目交互矩阵设置为  $Y = \{y_{ui} | u \in U, i \in I\}$ , 其中,当用户与项目存在交互时,  $y_{ui} = 1$ ; 当用户与项目不存在交互时,  $y_{ui} = 0$ . 知识图谱表示为  $G = \{(h, r, t) | h, t \in E, r \in R\}$ , 其中  $h$ 、 $r$  和  $t$  分别为头实体、关系、尾实体,  $E$  和  $R$  分别为  $G$  中的实体集和关系集.给定用户-项目交互矩阵  $Y$  和知识图谱  $G$ , 计算  $\hat{y}_{ui} = F(u, i | Y, G, \Theta)$ , 其中,  $\hat{y}_{ui}$  表示用户  $u$  点击项目  $i$  的概率,  $\Theta$  表示预测函数  $F$  的训练参数.

### 2.1 用户表征计算

用户-项目交互矩阵不仅能增强用户表示,还可以根据用户间的相似性探索项目特征<sup>[17]</sup>. KLGC 模型利用用户-项目交互矩阵生成用户邻居集合扩展实体的

邻域信息。

定义用户邻居集合为  $S_u$ , 使用皮尔逊相关系数<sup>[18]</sup> 计算用户  $u$  与用户  $v$  的相似度:

$$sim(u, v) = \frac{\sum_{i \in I_{uv}} (u_i - \bar{u})(v_i - \bar{v})}{\sqrt{\sum_{i \in I_{uv}} (u_i - \bar{u})^2} \sqrt{\sum_{i \in I_{uv}} (v_i - \bar{v})^2}} \quad (1)$$

其中,  $I_{uv}$  表示用户  $u$ 、 $v$  共同评分项目集合,  $u_i$  和  $v_i$  分别表示用户  $u$ 、 $v$  对交互项目  $i$  的兴趣度,  $\bar{u}$  和  $\bar{v}$  表示用户  $u$ 、 $v$  对交互的所有项目的兴趣平均值。  $sim$  的取值范围为  $[-1, 1]$ , 大于 0 为正相关, 小于 0 为负相关, 绝对值越大, 相关性越强。将相似度从大到小排序, 采样排名前  $n$  的用户:

$$S_u = \{u_1, u_2, \dots, u_n\} \quad (2)$$

假设用户  $u$  与项目  $i$  存在交互, 则  $y_{ui} = 1$ , 定义用户  $u$  的浏览记录为  $Y_u = \{i | y_{ui} = 1\}$ , 用户  $u$  及其邻居集合  $S_u$  的交互数据为  $Y_u^n = \{Y_u \cup Y_{u_1} \cup \dots \cup Y_{u_n} | n \in S_u\}$ , 以

$Y_u^n$  为知识图谱中的种子集, 探索用户的  $k$  跳偏好集合  $N_u^k$ :

$$N_u^k = \{(h, r, t) | (h, r, t) \in G \text{ and } h \in N_u^{k-1}\} \quad (3)$$

其中, 当  $k$  为 0 时:

$$N_u^0 = \{(h, r, t) | (h, r, t) \in G \text{ and } h \in Y_u^n\} \quad (4)$$

给定用户  $u$  的偏好集合  $N_u^k$ , 计算尾实体  $t$  嵌入到头实体  $h$  时的权值:

$$\pi(h, r, t) = (W_r e_t)^T \tanh(W_r e_h + e_r) \quad (5)$$

其中,  $W$  为可训练的参数。将相邻实体嵌入权重归一化表示为  $\tilde{\pi}(h, r, t)$ :

$$\tilde{\pi}(h, r, t) = \frac{\exp(\pi(h, r, t))}{\sum_{(h, r, t) \in N_u^k} \exp(\pi(h, r, t))} \quad (6)$$

得到嵌入权值后, 将  $N_u^k$  中的尾实体与相应权值加权求和, 其公式为:

$$u_{N_u^k} = \sum_{e \in N_u^k} \tilde{\pi}(h, r, t) e \quad (7)$$

其中,  $e$  为尾实体的向量表示。




图1 总体框架

为了得到更准确的用户偏好信息, 将节点的注意力权值排序, 采样排名前  $k_u$  的样本作为邻域:

$$N_u^k = \{e | e \sim \text{top}_{k_u}(\tilde{\pi}(h, r, t))\} \quad (8)$$

最后, 将用户表示  $u$  和其  $k$  阶邻域表示向量  $u_{N_u^k}$  使用轻量聚合器聚合, 得到用户  $u$  的最终嵌入表示, 其公式为:

$$agg_u = \sum_{k=0}^k a_k u_{N_u^k}^{(k)} + u \quad (9)$$

其中,  $k$  为迭代次数,  $a_k$  为第  $k$  层嵌入权重。

## 2.2 项目表征计算

为探索项目的高阶信息, 项目表征计算以用户嵌入表示和知识图谱作为输入, 利用注意力机制获得不

同关系对用户的重要程度,使用 LightGCN<sup>[8]</sup> 聚合邻域信息,得到项目的特征表示。

给定项目  $i$  与知识图谱  $G$ , 将  $i$  在  $G$  中的邻域信息表示为  $N_i$ 。由于不同用户其兴趣爱好不同, 为了提高用户对推荐结果的满意度, 故在聚合邻居实体时, 引入用户  $u$  对关系  $r$  的偏好, 其公式为:

$$\pi_r^u = a(u, r) \quad (10)$$

其中,  $u \in R^d, r \in R^d, a$  为内积操作, 将用户关系权值归一化表示为  $\tilde{\pi}_{r,i,e}^u$ :

$$\tilde{\pi}_{r,i,e}^u = \frac{\exp(\pi_{r,i,e}^u)}{\sum_{e \in N_i} \exp(\pi_{r,i,e}^u)} \quad (11)$$

其中,  $e$  为集合  $N_i$  中实体的向量表示,  $r_{i,e}$  表示项目  $i$  与实体  $e$  间的关系。

为得到项目  $i$  的邻域拓扑信息, 对  $N_i$  中的实体和用户关系之间的权值加权求和, 其公式为:

$$i_{N_i}^u = \sum_{e \in N_i} \tilde{\pi}_{r,i,e}^u e \quad (12)$$

由于项目的信息偏多, 为了选取更符合用户喜好的项目, 将用户关系权值排序, 采样排名前  $k_i$  的样本作为邻域:

$$N_i = \{e | e \sim \text{top}k_i(\tilde{\pi}_{r,i,e}^u)\} \quad (13)$$

最后, 使用轻量聚合器聚合项目表示  $i$  和其  $k$  阶邻居拓扑信息  $i_{N_i}^u$ , 得到项目  $i^u$  的最终向量表示, 其公式为:

$$\text{agg}_i^u = \sum_{k=0}^k a_k i_{N_i}^{(k)} + i \quad (14)$$

其中,  $k$  为迭代次数,  $a_k$  为第  $k$  层嵌入权重。

### 2.3 预测部分

由第 2.1 节和第 2.2 节得到用户表示  $u$  和项目表示  $i^u$ , 计算用户  $u$  点击项目  $i$  的概率  $\hat{y}_{ui}$ :

$$\hat{y}_{ui} = \sigma(u^T i^u) \quad (15)$$

其中,  $\sigma(x) = \frac{1}{1 + \exp(-x)}$  为 Sigmoid 函数。

为优化模型性能, 采用负采样训练模型, 损失函数如下:

$$L = \sum_{u \in U} \left( \sum_{(u,i) \in Y} T(y_{ui}, \hat{y}_{ui}) - \sum_{k=1}^{N_u} E_{I_k \sim p(i_k)} T(y_{ui}, \hat{y}_{ui}) \right) + \lambda \|F\|_2^2 \quad (16)$$

其中,  $T(y_{ui}, \hat{y}_{ui})$  为真实值与预测值之间的交叉熵损失,

$p$  为负采样分布,  $N_u$  为用户  $u$  的负采样个数,  $\|F\|_2^2$  为 L2 正则化防止过拟合。

## 3 实验分析

### 3.1 数据集

为了验证 KLGC 模型在不同场景的推荐性能, 实验选用两个公开数据集 Book-Crossing 和 Yelp2018, 这两个数据集被广泛应用于评估推荐算法性能。Book-Crossing 数据集是一个包含大约 14 万次图书评级的公开数据集。Yelp2018 数据集是 Yelp 网站相关业务、商户评论和用户数据的子集, 包含超过 118 万个商户评论。Book-Crossing 的用户项目交互数据相对于 Yelp-2018 数据集来说比较稀疏, 可以用来验证 KLGC 模型解决冷启动和数据稀疏问题的能力。数据集的详细数据见表 1。

表 1 数据集详细数据

| 数据集    | Book-Crossing | Yelp2018 |
|--------|---------------|----------|
| 用户数    | 17860         | 45919    |
| 物品数    | 14967         | 45538    |
| 交互记录数  | 139746        | 1185068  |
| KG三元组数 | 151500        | 1853704  |
| KG实体数  | 77903         | 90961    |
| SN关系数  | 25            | 42       |

### 3.2 实验设置

本文实验以 6:2:2 的比例将数据集随机划分为训练集、验证集和测试集。用户和物品表示向量的维度  $d$  为 64, 使用 Adam 优化器优化模型, 学习率默认为 0.001, batch-size 默认设置为 256, L2 正则化系数  $\lambda$  为 1E-4, 层组合系数  $a_k$  设置为  $1/(1+K)$ , 其中层数  $K$  设置为 2,  $k_u$  和  $k_i$  设置为 32。在对比模型默认参数设置下, 本文在下列两种实验场景中评估模型。

#### (1) 点击率 (CTR) 预测

将测试集放入训练后的模型, 使用 ROC 曲线下方面积 (AUC) 和准确率 (ACC) 指标评估 CTR 预测性能。AUC 的值通过对 ROC 曲线横轴进行积分获得, ROC 曲线横坐标为假阳率, 纵坐标为真阳率。ACC 的计算公式如下:

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

#### (2) Top-K 推荐

将测试集放入训练后的模型, 向用户推荐点击率



排名前  $K$  的物品, 使用预测率 (*precision*) 和召回率 (*recall*) 指标评估模型推荐性能。

*precision* 指标主要是指向用户推荐的项目中, 用户感兴趣的项目占的比例。计算公式如下:

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

*recall* 指标主要是指向用户推荐的项目中用户感兴趣的项目占用户交互项目总数的比例。计算公式如下:

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

其中,  $TP$  (true positive) 表示正样本被预测为正;  $TN$  (true negative) 表示负样本被预测为负;  $FP$  (false positive) 表示负样本被预测为正;  $FN$  (false negative) 表示正样本被预测为负。

### 3.3 对比模型

为评估 KLGC 模型的性能, 本文使用轻量图卷积网络模型 LightGCN<sup>[8]</sup>, 经典的知识图谱推荐模型 RippleNet<sup>[13]</sup>、融合知识图谱和图卷积网络的新近推荐模型 KG CN<sup>[15]</sup> 和 SP GCN<sup>[19]</sup> 作为对比的基线模型。

LightGCN<sup>[8]</sup>: 该模型去除了传统图卷积网络中的特征变换和非线性激活模块, 在不影响推荐性能的前提下极大地降低了模型复杂度。

RippleNet<sup>[13]</sup>: 该模型首次将基于嵌入的方法和基于路径的方法结合, 通过在知识图谱上传播用户偏好, 扩展用户潜在兴趣, 在增强用户表示方面表现良好。

KG CN<sup>[15]</sup>: 利用图卷积网络聚合知识图谱中实体的邻域信息, 丰富物品端的表示, 得到用户对物品端的偏好概率。

SP GCN<sup>[19]</sup>: 在 KG CN 模型基础上, 简化了图卷积网络中的非线性激活模块和特征变换模块, 提升了模型预测的准确性。

### 3.4 实验结果分析

#### 3.4.1 性能分析

表 2 为基线模型在 CTR 预测上的结果, 观察表中数据可知, KLGC 模型在两个数据集上均产生了最佳性能。在数据集 Book-Crossing 中, KLGC 模型相比于最优算法, *AUC* 提升了 1.8%, *ACC* 提升了 2.3%。在数据集 Yelp2018 中, 相比于最优算法, *AUC* 提升了 1.2%, *ACC* 提升了 1.4%。同时, 在 Top- $K$  推荐中推荐性能也优于其他模型。Top- $K$  推荐中,  $K$  的取值会影响推荐结果, 将  $K$  设置为 {1, 5, 10, 20, 30, 50}, 观察预测率和召回率的变化。从图 2 和图 3 可以看出, 在数据量较小的数据集 Book-Crossing 上,  $K=10$  时, 推荐性能最优。对于数据量较大的 Yelp2018 数据集,  $K=20$  时获得最优性能。

表 2 *AUC* 和 *ACC* 性能对比

| Model     | Book-Crossing |            | Yelp2018   |            |
|-----------|---------------|------------|------------|------------|
|           | <i>AUC</i>    | <i>ACC</i> | <i>AUC</i> | <i>ACC</i> |
| LightGCN  | 0.697         | 0.639      | 0.854      | 0.809      |
| RippleNet | 0.723         | 0.659      | 0.863      | 0.818      |
| KG CN     | 0.692         | 0.632      | 0.846      | 0.803      |
| SP GCN    | 0.727         | 0.665      | 0.866      | 0.821      |
| KLGC      | 0.745         | 0.688      | 0.878      | 0.835      |




图 2 Book-Crossing 数据集上 Top- $K$  推荐结果

从图 2 和图 3 可以看出, KLGC 模型在两个数据集中的准确率和召回率都优于其他的基线模型。通过对比实验分析可知, RippleNet 通过用户的浏览记录建模用户偏好, 学习了用户表示但没有学习项目表示。与

RippleNet 类似, KG CN 利用卷积网络聚合知识图谱的信息, 但忽略了对用户偏好的建模。两个基线都没有同时利用用户向量表示和项目向量表示预测评分, 故其性能相对于 KLGC 较差。




图3 Yelp2018数据集上 Top-K 推荐结果

基线 SPGCN 优于 KGCN, 说明在传统 GCN 上去除特征转换和非线性激活模块并不影响推荐性能, 同时, SPGCN 推荐效果优于 LightGCN 表明在推荐系统中引入知识图谱有利于提升推荐性能. SPGCN 在 KGCN 基础改进, 同样忽视了对用户端的建模, KLGC 同时对用户和项目两端建模, 更好地挖掘了用户的潜在兴趣, 使推荐结果更准确.

### 3.4.2 参数设置

由表 3 可知, 邻居数  $n$  在 (10, 20) 时, 推荐性能最佳. 邻居数  $n$  很小时, 如果邻居集合中存在用户与目标用户的偏好差距很大, 推荐结果将存在较大误差; 当邻居数  $n$  很大时, 邻居集合中有很多与用户爱好有较大偏差的用户, 增加不可预测的噪声数据, 进而使得性能下降.

表3 邻居数采样  $n$  对模型性能的影响

| 数据集           | 2     | 5     | 10    | 20    | 50    |
|---------------|-------|-------|-------|-------|-------|
| Book-Crossing | 0.735 | 0.732 | 0.738 | 0.740 | 0.732 |
| Yelp2018      | 0.868 | 0.871 | 0.874 | 0.871 | 0.865 |

表 4 表示卷积层数对 AUC 的影响, 从表中可以看出, 卷积层从 1 增加到 2 时, 模型的性能效果提升, 表明增加层数可以聚合更多邻域信息; 随着层数持续增加, 模型引入大量噪声, 推荐性能开始下降.

表4 不同卷积层数  $K$  对模型性能的影响

| 数据集           | 1     | 2     | 3     | 4     |
|---------------|-------|-------|-------|-------|
| Book-Crossing | 0.732 | 0.741 | 0.744 | 0.738 |
| Yelp2018      | 0.869 | 0.874 | 0.871 | 0.867 |

### 3.4.3 消融实验

为验证非线性激活函数和特征变换模型对性能的影响, 用  $KLGC_{+f}$  表示在 KLGC 模型上引入特征转换模块,  $KLGC_{+w}$  表示在 KLGC 模型上引入非线性激活

模块, 非线性激活函数选择 LeakyReLU.

由表 5 观察可知, 在数据集 Book-Crossing 和 Yelp2018 上实验, 在 KLGC 上加入激活函数或特征变换, 都会影响模型性能. 相比较而言, KLGC 模型性能最优, 与 LightGCN 的实验结果一致. 将 KLGC 模型平均迭代一次的时间 (time) 设置为 1, 计算出  $KLGC_{+f}$  和  $KLGC_{+w}$  与 KLGC 迭代一次所需时间的对比度. 由表可知, KLGC 运行时间最短, 这表明在传统的图卷积网络中去掉特征变换和非线性激活模块不仅降低了模型复杂度, 而且提高了模型推荐性能.

表5 非线性激活函数和特征变换对性能的影响

| Model       | Book-Crossing |       | Yelp2018 |       |
|-------------|---------------|-------|----------|-------|
|             | AUC           | 时间对比度 | AUC      | 时间对比度 |
| $KLGC_{+f}$ | 0.736         | 1.253 | 0.867    | 1.343 |
| $KLGC_{+w}$ | 0.734         | 1.082 | 0.861    | 1.126 |
| KLGC        | 0.741         | 1     | 0.875    | 1     |

## 4 结论与展望

本文提出融合知识图谱和轻量图卷积网络的推荐算法 (KLGC). 算法引入用户邻居集合和轻量图卷积网络来缓解用户-项目交互数据稀疏和模型复杂度高的问题, 提升推荐性能. 不同用户对项目的偏好不同, 模型从用户和项目两端建模; 在用户端, 利用知识图谱捕获用户偏好信息, 挖掘用户潜在兴趣得到用户表示. 在项目端, 利用知识图谱获取用户偏好的项目信息, 聚合项目邻域信息生成嵌入表示. 通过在两个公开数据集上的实验分析, 相较于对比模型 KLGC 模型的推荐性能更优, 适用于个性化推荐场景, 如学习资源推荐、就业推荐等. 但模型没有考虑个性化推荐场景中用户兴趣动态变化的问题, 在后续研究中将考

虑结合动态推荐模型捕获用户的动态兴趣,进一步提升推荐性能。

### 参考文献

- 1 Ai QY, Azizi V, Chen X, *et al.* 2018. Learning heterogeneous knowledge base embeddings for explainable recommendation. *Algorithms*, 2018, 11(9): 137. [doi: [10.3390/a11090137](https://doi.org/10.3390/a11090137)]
- 2 Tian X, Ding Q, Liao ZH, *et al.* Survey on deep learning based news recommendation algorithm. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(6): 971–998. [doi: [10.3778/j.issn.1673-9418.2007021](https://doi.org/10.3778/j.issn.1673-9418.2007021)]
- 3 Zhu K, Xiao YY, Zheng WG, *et al.* A novel context-aware mobile application recommendation approach based on users behavior trajectories. *IEEE Access*, 2021, 9: 1362–1375. [doi: [10.1109/ACCESS.2020.3046654](https://doi.org/10.1109/ACCESS.2020.3046654)]
- 4 Du YT, Zhu XJ, Chen L, *et al.* HAKG: Hierarchy-aware knowledge gated network for recommendation. *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Madrid: ACM, 2022. 1390–1400. [doi: [10.1145/3477495.3531987](https://doi.org/10.1145/3477495.3531987)]
- 5 Zhai FB, Li BZ. Point of interest recommendation based on graph convolutional neural network. *Journal of Physics: Conference Series*, 2021, 1883(1): 012132. [doi: [10.1088/1742-6596/1883/1/012132](https://doi.org/10.1088/1742-6596/1883/1/012132)]
- 6 郭晓旺, 夏鸿斌, 刘渊. 融合知识图谱与图卷积网络的混合推荐模型. *计算机科学与探索*, 2022, 16(6): 1343–1353. [doi: [10.3778/j.issn.1673-9418.2110057](https://doi.org/10.3778/j.issn.1673-9418.2110057)]
- 7 朱冬亮, 文奕, 万子琛. 基于知识图谱的推荐系统研究综述. *数据分析与知识发现*, 2021, 5(12): 1–13.
- 8 He XN, 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*. Xi'an: ACM, 2020. 639–648. [doi: [10.1145/3397271.3401063](https://doi.org/10.1145/3397271.3401063)]
- 9 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](https://doi.org/10.1109/TKDE.2018.2833443)]
- 10 Ma C, Ma LH, Zhang YX, *et al.* Knowledge-enhanced top-K recommendation in Poincaré ball. *Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Palo Alto: AAAI Press, 2021. 4285–4293. [doi: [10.1609/aaai.v35i5.16553](https://doi.org/10.1609/aaai.v35i5.16553)]
- 11 Cao YX, Wang X, He XN, *et al.* Unifying knowledge graph learning and recommendation: Towards a better understanding of user preferences. *Proceedings of the 28th International World Wide Web Conference*. San Francisco: ACM, 2019. 151–161. [doi: [10.1145/3308558.3313705](https://doi.org/10.1145/3308558.3313705)]
- 12 Hu BB, Shi C, Zhao WX, *et al.* Leveraging meta-path based context for top-N recommendation with a neural co-attention model. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London: ACM, 2018. 1531–1540. [doi: [10.1145/3219819.3219965](https://doi.org/10.1145/3219819.3219965)]
- 13 Wang HW, Zhang FZ, Wang JL, *et al.* RippleNet: Propagating user preferences on the knowledge graph for recommender systems. *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. Torino: ACM, 2018. 417–426. [doi: [10.1145/3269206.3271739](https://doi.org/10.1145/3269206.3271739)]
- 14 Cai HY, Zheng VW, Chang KCC. A comprehensive survey of graph embedding: Problems, techniques, and applications. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(9): 1616–1637. [doi: [10.1109/TKDE.2018.2807452](https://doi.org/10.1109/TKDE.2018.2807452)]
- 15 Wang H, Zhao M, Xie X, *et al.* Knowledge graph convolutional networks for recommender systems. *Proceedings of the 28th International World Wide Web Conference*. San Francisco: ACM, 2019. 3307–3313. [doi: [10.1145/3308558.3313417](https://doi.org/10.1145/3308558.3313417)]
- 16 李想, 杨兴耀, 于炯等. 基于知识图谱卷积网络的双端推荐算法. *计算机科学与探索*, 2022, 16(1): 176–184.
- 17 Zhang LS, Kang Z, Sun XX, *et al.* KCRec: Knowledge-aware representation graph convolutional network for recommendation. *Knowledge-based Systems*, 2021, 230: 107399. [doi: [10.1016/j.knsys.2021.107399](https://doi.org/10.1016/j.knsys.2021.107399)]
- 18 Chang C, Wang QY, Jiang JC, *et al.* Lithium-ion battery state of health estimation using the incremental capacity and wavelet neural networks with genetic algorithm. *Journal of Energy Storage*, 2021, 38: 102570. [doi: [10.1016/j.est.2021.102570](https://doi.org/10.1016/j.est.2021.102570)]
- 19 马甜甜, 杨长春, 严鑫杰, 等. 融合知识图谱和轻量级图卷积网络推荐系统的研究. *智能系统学报*, 2022, 17(4): 721–727. [doi: [10.11992/tis.202107016](https://doi.org/10.11992/tis.202107016)]

(校对责编: 牛欣悦)