

文章编号: 2095-2163(2024)02-0035-06

中图分类号: TP391.3;TP391.1;TP183

文献标志码: A

# 基于用户行为及知识传播的图神经网络推荐系统

杨中金

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

**摘要:** 协同过滤算法存在数据稀疏和冷启动问题,当前的推荐方法普遍引入知识图谱来缓解协同过滤算法的缺陷,但这些方法大都专注于利用知识图谱来构建用户及物品的特征表示,忽略了对用户交互信息的有效利用。本文提出了一种基于用户行为和知识图谱的推荐方法,该方法由交互传播以及知识传播两部分组成。前者通过图神经网络,利用用户-物品交互图来构建用户物品的高阶交互特征;后者利用知识图谱中传播得到相关实体来补充对物品的描述。在两个基准数据集上的大量实验表明,相对于基线模型,本文提出的基于用户行为及知识传播的图神经网络推荐系统具有较好的推荐效果以及泛化能力。

**关键词:** 协同过滤; 推荐系统; 用户-物品交互图; 知识图谱

## GPUI: A graph neural network for recommendation system based on propagation of user behavior and item knowledge

YANG Zhongjin

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

**Abstract:** Collaborative filtering algorithm has the problems of data sparsity and cold start. Current recommender systems generally introduce knowledge graph (KG) to alleviate the defects. However, these KG-aware recommendation methods solely focus on constructing feature representation of users and items through KG, ignoring the effective utilization of user interactive information. This paper proposes a recommendation method based on user behavior and knowledge graph, which consists of interaction propagation and knowledge propagation. The former utilizes user-item interaction graph through GNN to construct high-order interaction feature of users and items. The latter exploits related entities from KG to complement the description of the item. Extensive experiments show that compared with the baseline models, the proposed system has better recommendation effect and the ability of generalization.

**Key words:** collaborative filtering; recommender system; user-item interaction graph; knowledge graph

## 0 引言

互联网飞速发展,商业应用对于个性化推荐的需求愈发强烈。用户希望从海量的内容中得到个性化的服务,平台商也希望能妥善处理海量的数据,合理地分发内容,增加用户的粘性。在这个背景下,用于信息过滤的推荐系统(RS)被广泛应用于个性化推荐任务中。推荐系统基于用户的交互历史,对用户的特征、属性建模,构建用户的兴趣画像,并推送其可能感兴趣的内容。协同过滤(CF)技术因强大的利用用户行为捕捉用户偏好的优势,已成为推荐系统中最常见、应用最为广泛的策略<sup>[1]</sup>。但是CF

方法存在数据稀疏和冷启动问题,导致其无法对所有用户或物品进行特征建模<sup>[2]</sup>。因此,将知识图谱(KG)作为辅助信息引入推荐系统来缓解当前协同过滤算法缺陷<sup>[3]</sup>。

引入KG的推荐方法相对于传统的CF方法更准确、泛化能力更强,更适应不同的推荐场景,但這些知识感知的方法着重于利用KG来构建推荐系统中节点的特征表示,却忽略了对推荐更重要的用户交互记录的有效利用<sup>[4]</sup>。协作感知的知识图谱传播方法(CKAN)强调了潜藏在用户物品交互中协作信号的重要性,将被推荐的用户交互过的物品,以及与被推荐物品存在共同消费者的物品视为协作信

**基金项目:** 国家自然科学基金(61772342)。

**作者简介:** 杨中金(1997-),男,硕士研究生,主要研究方向:推荐系统。

**收稿日期:** 2023-03-05

号,将这些协作信号作为传播实体在知识图谱中多次传播获取知识关联,却忽略了交互信息中潜藏的高阶交互特征<sup>[5]</sup>。

对于用户交互数据以及 KG 的同时利用不仅能够更充分的构建用户物品的特征表示,而且能够增强推荐系统的泛化能力。知识图谱在稀疏程度不同的数据集上作用并不相同,在用户交互频繁的数据集上,知识图谱作为辅助信息的作用几乎失效,而在稀疏的数据集上,知识图谱因为补充了大量关联信息,在很大程度上有利于特征的建模。在这两种图结构信息上分别构建交互特征以及知识特征,并通过超参数来调整其对模型的影响,可能会使模型取得更好的推荐效果。

本文提出了一种基于用户行为以及知识传播的推荐系统(GPUI),旨在利用用户行为和 KG 预测特定的用户与物品交互的概率。模型由两部分组成,即交互传播以及知识传播,前者通过图神经网络(GNN)利用交互数据来构建用户物品的高阶交互特征;后者利用知识图谱中传播得到相关实体来补充物品的描述。在 Last.FM、MovieLens-1M 两个基准数据集上进行的实验结果证明,与其他方法相比,GPUI 在推荐性能以及泛化能力上都具有一定优势。

## 1 相关工作

### 1.1 知识图谱

利用知识图谱的推荐方法,通过学习知识图谱中相关实体、关系及路径的向量嵌入,来辅助增强用户物品的特征表示<sup>[6]</sup>。根据对知识图谱利用方式的不同,可以分为基于嵌入、基于路径以及基于传播的方法<sup>[5]</sup>。基于嵌入的方法通过知识图嵌入算法,例如 TansR, TransD 等,将知识图谱中的实体的向量,预训练到一个低维的向量空间中,并将学习好的实体嵌入融入到推荐任务中;基于路径的方法通过学习 KG 中实体间连接的多种路径的嵌入来提高推荐结果的准确性;基于路径的方法是当前较为热门的推荐方法,通过获取 KG 中的高阶的关系信息来构建更精细的用户物品的表示。将相关的物品在 KG 上迭代传播得到多跳邻居实体,通过聚合其向量增强用户物品的特征表示。

用户物品交互图(UIG)及知识图谱(KG)的结构如图1所示,可知结合用户的交互历史在 KG 中多次传播获取相关三元组的过程。以用户  $u_2$  为例,物品  $v_3, v_5$  是其交互过的物品,通过 UIG-KG 的对应关系  $(v_3, e_1)$  以及  $(v_5, e_2)$  可知,在 KG 上传播的初

始实体是  $e_1, e_2$ 。在第一跳的传播中搜索 KG 中的三元组  $(e_1, r_{13}, e_3)$ 、 $(e_1, r_{14}, e_4)$ 、 $(e_2, r_{26}, e_6)$ , 这些三元组的头部实体是  $e_1$  或  $e_2$ , 下一次传播的,将三元组中的尾部实体集合  $\{e_3, e_4, e_6\}$  作为传播实体。如此,在 KG 上多次传播可以得到相关的三元组集合,用于构建知识特征。

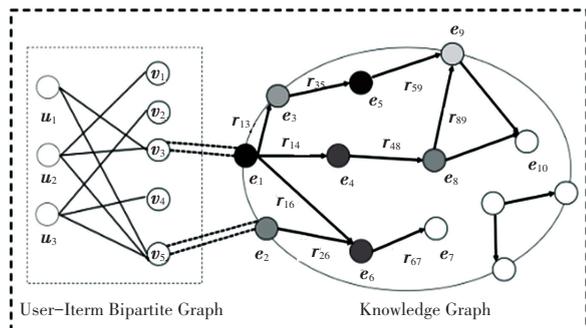


图1 用户物品交互图及知识图谱

Fig. 1 User-Item Interaction Graph and Knowledge Graph

### 1.2 图神经网络

传统的方法在处理图结构信息时,会将图预处理成一组平面向量,再利用机器学习方法去完成下游的任务,这种方式无疑会丢失图中重要的拓扑信息,影响模型的准确性及泛化能力<sup>[7]</sup>。由于 GNN 在大规模的图数据上学习的独特优势,当前的推荐方法大多利用 GNN 来构建节点的特征表示<sup>[8]</sup>。

GNN 的核心是特征聚合,通过聚合节点本身的特征以及邻居节点的特征来生成节点新的特征表示,并且通过迭代聚合的过程来得到节点的高阶表示<sup>[9]</sup>。神经图协同过滤方法(NGCF)是一种基于 GNN 的协同过滤方法,主要利用用户的交互数据来构建节点的特征向量,并且将聚合邻域特征的过程反复迭代,以获得节点的高阶交互特征<sup>[10]</sup>。轻量级的神经图协同过滤方法(LightGCN)在 NGCF 的基础上提出了一个简单,易于训练的模型,只保留了 GNN 方法中最重要的部分-领域特征聚合,通过在用户物品交互图上迭代传播来学习用户物品的特征表示<sup>[11]</sup>。

对于 KG 上的领域信息,聚合相类似,将物品自身以及物品在 KG 中方式与 NGCF 的相关节点的特征聚合,得到物品的知识特征。相对于用户的交互数据,KG 中实体间的关系更加多样,强弱不同,许多方法会使用图注意力机制来区分节点的重要性,得到关系权重,再对实体的特征进行加权求和。知识图注意力网络推荐方法(KGAT)将用户物品交互图(UIG)和知识图谱(KG)结合成一个统一的图

(CKG), 首先利用 transR 来预训练 KG 中实体和关系的向量表示, 之后使用注意力机制来衡量不同邻居节点的重要性, 在每一层传播中, 通过迭代聚合节点在 KG 中的邻域特征信息, 来更新节点的特征表示。

## 2 问题定义

给定一个推荐场景,  $U = \{u_1, u_2, \dots, u_M\}$  和  $V = \{v_1, v_2, \dots, v_N\}$  分别表示用户以及物品集合。用户和物品之间的历史交互数据可以描述为一个二部图, 称为用户物品交互图 (UIG), 用  $I_g = \{ \langle u, v, y_{uv} \rangle \mid u \in U, v \in V, y_{uv} \in \mathbb{R} \}$  表示, 其中  $y_{uv}$  是一个表明用户  $u$  与物品  $v$  是否存在交互关系的标签。从  $I_g$  中提取出一个  $M \times N$  的二进制矩阵  $Y$ , 对于矩阵中的每一对  $(i, j)$ , 当用户  $u_i$  与物品  $v_j$  产生了交互时, 矩阵  $Y$  中的元素  $y_{ij} = 1$ , 否则  $y_{ij} = 0$ 。设  $G = (h, r, t) \mid h, t \in \mathbb{E}, r \in \mathbb{R}$  表示 KG, 其中  $\mathbb{E}$  表示 KG 中的实体的集合,  $\mathbb{R}$  表示 KG 中边的集合, 即实体间关系的集合。对于任意一个三元组  $(h, r, t) \in G, h$  表示头实体,  $t$  表示尾实体,  $r$  表示关系实体, 表明实体  $h$  与实体  $t$  之间存在着关系  $r$ 。本文引入了一个二元组集合  $A = \{ \langle e, v \rangle \mid e \in \mathbb{E}, v \in V \}$  来表明实体集  $\mathbb{E}$  中的实体与物品集  $V$  中物品之间的对应关系。

本文研究的目的是预测特定的用户和物品之间存在交互的可能性。给定知识图谱  $G$  以及部分用户-物品交互矩阵  $Y'$  作为训练集, 通过学习一个函数  $\hat{y}_{uv} = f(e_u, e_v, G, Y'; \Theta)$  来预测用户  $u$  与物品  $v$  是否会发生交互, 其中  $e_u$  和  $e_v$  表示用户  $u$  与物品  $v$  的嵌入向量,  $\Theta$  表示模型的参数集合。为了得到最优的预测函数  $f(\cdot)$ , 需要最小化训练损失来确定  $\Theta$  中参数的最优值, 公式(1):

$$\Theta = \operatorname{argmin}_{\Theta} \frac{1}{|M' \times N'|} \sum_{u \in U_{Y'}, v \in V_{Y'}} L(y_{uv}, \hat{y}_{uv}) \quad (1)$$

其中,  $U_{Y'}$  和  $V_{Y'}$  表示在训练矩阵  $Y'$  中的用户和物品集合;  $M'$  和  $N'$  是  $U_{Y'}$  和  $V_{Y'}$  集合的大小;  $L(\cdot)$  是训练的损失函数。

## 3 方法

本文提出一种基于用户行为以及知识传播的推荐方法 (GPUI), 目标是预测特定用户以及物品之间发生交互的概率, 模型总体框架如图 2 所示。输入用户物品交互矩阵和知识图谱后, 通过交互传播和知识传播两个过程来完成模型的计算。在交互传播中, 利用 GNN, 通过迭代聚合交互节点的特征来构建用户及物品的交互特征。为了丰富物品的描述, 利用知识传播, 在知识图谱中沿着链接扩展多个相关三元组集合, 获取知识特征。

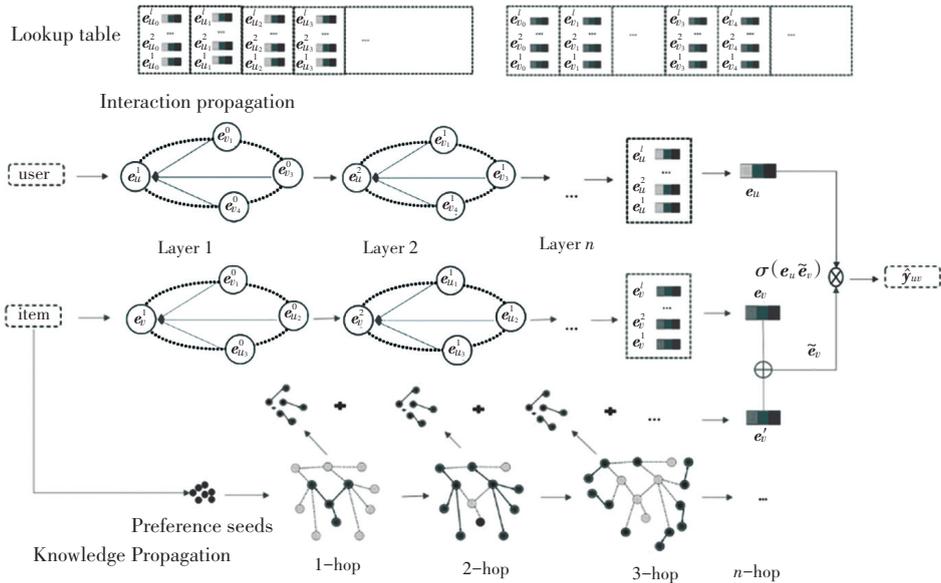


图 2 模型总体框架

Fig. 2 Overall framework of the model

### 3.1 交互传播

用户的特征表示通过用户交互过的物品的特征获得; 同理, 与物品交互过的用户可以帮助构建该物

品的嵌入向量。运用这个思想, 交互传播通过迭代聚合用户物品交互图上节点的邻域特征来获得节点的高阶交互特征。

### 3.1.1 初阶特征聚合

在初阶交互特征传播的过程中,用户及物品的初阶交互特征是通过聚合其交互节点第0阶的嵌入向量得来。而这些交互节点第0阶的嵌入向量是直接通过其id随机初始化得来。初阶特征聚合见式(2)和式(3):

$$e_u^1 = \frac{\left(\sum_{v \in \mathcal{V}_u} e_v^0 + e_u^0\right)}{(|\mathcal{V}_u| + 1)} \quad (2)$$

$$e_v^1 = \frac{\left(\sum_{u \in \mathcal{U}_v} e_u^0 + e_v^0\right)}{(|\mathcal{U}_v| + 1)} \quad (3)$$

其中,  $\mathcal{V}_u$  表示用户  $u$  交互过的物品的集合;  $\mathcal{U}_v$  表示物品  $v$  交互过的用户集合;  $|\mathcal{V}_u|$  和  $|\mathcal{U}_v|$  表示的是集合  $\mathcal{V}_u$  及  $\mathcal{U}_v$  的大小。

### 3.1.2 高阶特征聚合

构建用户及物品初阶的交互特征后,高阶的特征聚合过程将会反复地应用在节点上,节点特征聚合的过程如图3所示,可知节点第  $l$  层的传播过程需要用到第  $l-1$  层的邻居节点的向量嵌入。高阶特征聚合见式(4)和式(5):

$$e_u^l = \frac{\sum_{v \in \mathcal{V}_u} e_v^{l-1}}{|\mathcal{V}_u|} \quad (4)$$

$$e_v^l = \frac{\sum_{u \in \mathcal{U}_v} e_u^{l-1}}{|\mathcal{U}_v|} \quad (5)$$

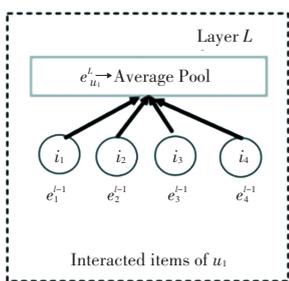


图3 交互特征聚合

Fig. 3 Fusion of interaction feature

迭代更新的目的是为了获取节点高阶的交互特征,迭代的次数越高,每次聚合所关联的节点越多,更接近获得全局的特征<sup>[12]</sup>。同时,本方法以对邻域特征求平均的方式来处理节点特征聚合的过程;其次,减少非线性激活函数的使用,以只对邻域特征求平均的方式简化特征聚合的模块,减少节点的特征在多次转换中的损失。

### 3.1.3 交互特征结合

多层传播后,将每一层聚合得到的嵌入向量相加,

得到用户及物品最终的交互特征表示,式(6)和式(7):

$$e_u = e_u^1 + e_u^2 + \dots + e_u^{m_l} \quad (6)$$

$$e_v = e_v^1 + e_v^2 + \dots + e_v^{m_l} \quad (7)$$

其中,  $m_l$  表示传播的最后一层。

## 3.2 知识传播

当前的推荐方法在 KG 中的传播目的是获得相关的扩展三元组,然后捕获其中的知识特征,用于构建用户或物品的知识表示。

### 3.2.1 知识三元组

对于物品  $v$ , 在 KG 中传播的初始实体是与其存在共同消费者的物品在 KG 中对应的实体。给定物品-实体对应集合  $\mathbf{A}$  及用户物品交互矩阵  $\mathbf{Y}'$ , 用户  $u$  与物品  $v$  的传播初始实体集合表示为式(8)和式(9):

$$\mathbb{E}_v^0 = \{e \mid (v', e) \in \mathbf{A} \text{ and } v' \in \mathcal{V}_v\} \quad (8)$$

$$\mathcal{V}_v = \{v' \mid u' \in \mathcal{U}_v, \text{ and } y_{u'v'} = 1\} \quad (9)$$

其中,  $u'$  表示与被推荐的物品  $v$  交互过的用户;  $v'$  表示与  $u'$  交互过的物品;  $(v', e)$  表示一个对应关系。

在 KG 中的实体  $e$  能够与用户物品交互图中的物品  $v'$  相对应,  $\mathcal{V}_v$  表示与物品  $v$  存在共同消费者的物品集合。基于初始的传播实体,第  $n$  跳的传播实体集可定义为式(10):

$$\mathbb{E}_v^n = \{t \mid (h, r, t) \in \mathbf{G} \text{ and } h \in \mathbb{E}_v^{n-1}\} \quad (10)$$

得到第  $n-1$  跳的传播实体,物品  $v$  第  $n$  跳知识传播得到的三元组集合  $\mathcal{S}_v^n$ , 式(11):

$$\mathcal{S}_v^n = \{(h, r, t) \mid (h, r, t) \in \mathbf{G} \text{ and } h \in \mathbb{E}_v^{n-1}\} \quad (11)$$

跳数  $n$  意味着与初始传播实体的距离。通常在 KG 上  $n$  次传播后,得到的三元组的数量会呈指数级增长,通过随机抽样的方法将三元组集合控制在一个固定的数量。

### 3.2.2 知识特征聚合

给定任意三元组  $(h_i, r_i, t_i)$ , 定义相关系数  $p_i$  来衡量物品  $v$  与尾部实体  $t_i$  在关系  $r_i$  上的相似性。得到第  $l$  跳的三元组集合  $\mathcal{S}_v^l$  后,通过非线性激活函数 softmax 对集合中每个三元组  $(h_i, r_i, t_i)$  中  $h_i, r_i$  与物品  $v$  的特征表示的乘积归一化得到相关系数,式(12):

$$p_i = \text{softmax}(\mathbf{v}^T \mathbf{R}_i \mathbf{h}_i) = \frac{\exp(\mathbf{v}^T \mathbf{R}_i \mathbf{h}_i)}{\sum_{(h,r,t) \in \mathcal{S}_v^l} \exp(\mathbf{v}^T \mathbf{R} \mathbf{h})} \quad (12)$$

其中,  $\mathbf{v}$  和  $\mathbf{h}_i$  是物品  $v$  和头部实体  $h_i$  的嵌入向量,  $\mathbf{R}_i$  是度量  $\mathbf{v}$  和  $\mathbf{h}_i$  之间关系的嵌入矩阵。

计算每个实体  $t_i$  相关系数  $p_i$ , 表示项目  $v$  和实

体  $t_i$  之间的相似的程度。在不同的关系  $r_i$  上, 实体  $t_i$  与物品  $v$  具有不同的相似之处。例如, 在音乐推荐中, “fantasy” 和 “Try” 音乐相似, 因为其拥有共同的作者周杰伦, 而本文认为 “fantasy” 和 “Valentine” 音乐相似, 因为其都是流行音乐。

得到了相关系数  $p_i$ , 物品  $v$  第  $n$  次传播得到的知识特征可以表示为式(13):

$$\mathbf{e}_v^{l'} = \sum_{(h_i, r_i, t_i) \in \mathcal{S}_i^k} p_i \mathbf{t}_i \quad (13)$$

### 3.2.3 知识特征结合

与交互传播中交互特征结合的方式相同, 将每跳传播得到的知识特征简单相加, 就得到了物品  $v$  最终的知识特征, 式(14):

$$\mathbf{e}_v' = \mathbf{e}_v^{1'} + \mathbf{e}_v^{2'} + \dots + \mathbf{e}_v^{n_l'}$$

其中,  $n_l$  表示知识传播的最后一跳。

物品  $v$  最终的表示由其交互特征  $\mathbf{e}_v$  以及知识特征  $\mathbf{e}_v'$  相加得到, 式(15):

$$\tilde{\mathbf{e}}_v = \mathbf{e}_v + \mathbf{e}_v' \quad (15)$$

## 3.3 模型预测

将用户  $u$  和物品  $v$  的特征向量  $\mathbf{e}_u$  和  $\tilde{\mathbf{e}}_v$  的内积施加 Sigmoid 函数, 得到模型的预测分数, 得到的分数将作为用户  $u$  和物品  $v$  交互的概率, 式(16):

$$\hat{y}_{uv} = \sigma(\mathbf{e}_u \mathbf{e}_v) \quad (16)$$

其中,  $\sigma$  表示非线性激活函数 Sigmoid。

## 4 实验与分析

### 4.1 数据集与基线模型

实验使用 Last.FM 及 MovieLens-1M 两个数据集。数据集的详细数据见表 1。指标 density 是指数据集的稀疏程度, 由交互数除以用户数与物品数的乘积得出。由表 1 中数据可知, MovieLens-1M 数据集相对密集, 其知识图谱也相对更庞大; Last.FM 数据集相对稀疏, 其知识图谱相对小一些。

表 1 数据集统计数据

Table 1 Dataset statistics

图	指标	Last.FM	MovieLens-1M
用户物品交互图	用户	1 872	6 036
	物品	3 846	2 445
	交互	42 346	753 772
	稠密度	0.005 88	0.050 10
知识图谱	实体	9 366	182 011
	关系	60	12

为了验证模型的性能, 将 GPUUI 与以下基线模

型做比较:

(1) RippleNet 沿着 KG 中的链接多次传播, 拓展用户的偏好<sup>[4]</sup>;

(2) KGAT 是一个基于 GNN 的模型, 将 UIG 和 KG 结合为一个统一的图 CKG<sup>[6]</sup>;

(3) KGCN 使用 GNN 结合知识图谱中的邻居信息来聚合节点的表示<sup>[9]</sup>;

(4) KCRec 是一个捕捉用户间及物品间关联的知识感知的推荐系统<sup>[13]</sup>;

(5) HRS 是一个基于知识图嵌入和注意力机制的混合推荐系统<sup>[14]</sup>;

(6) ST\_RippleNet 是当前领先的推荐模型, 利用 KG 获取用户潜在的兴趣, 并利用三元组注意力机制来挖掘 KG 中的有效信息<sup>[15]</sup>;

(7) RKAC 是当前最先进的基于传播的模型, 减少了聚集知识图谱中领域信息过程中不相关的实体, 以获得用户和物品的准确表示<sup>[16]</sup>。

数据集按 6:2:2 的比例随机分为训练集、验证集和测试集, 每个实验重复 5 次, 取平均性能。

将 GPUUI 应用到点击预测 (CTR) 的推荐任务中; 预测测试集中每条记录的用户与物品交互的概率。在 CTR 预测中, 评价指标为准确率 (ACC), 受试者工作特征曲线下的面积 (AUC)。

### 4.2 推荐性能

在不同数据集下, 将 GPUUI 与基线模型的性能做对比, 实验结果见表 2。

表 2 推荐性能比较

Table 2 Overall performance

模型	Last.FM		MovieLens-1M	
	AUC	ACC	AUC	ACC
KGAT(2019)	0.744	0.673	0.801	0.742
RippleNet(2018)	0.810	0.744	0.920	0.842
KGAT(2019)	0.773	0.724	0.922	0.833
KCRec(2021)	0.800	0.732	0.916	0.840
HRS(2021)	0.818	0.754	0.921	0.847
ST_RippleNet(2021)	0.828	0.761	0.922	0.843
RKAC(2022)	0.854	0.764	0.922	0.847
GPUUI	<b>0.859</b>	<b>0.804</b>	<b>0.926</b>	<b>0.852</b>

实验结果表明, 在 CTR 推荐中, GPUUI 在两个基准数据集上都优于对比模型。特别是与近年来最好的两个模型 ST\_RippleNet 和 RKAC 相比, 本文提出的 GPUUI 模型在两个数据集上, ACC 分别比 RKAC 提高了 4.0% 和 0.5%, AUC 分别比 ST\_RippleNet 提高了 3.1% 和 0.4%。

所有的方法在相对密集的数据集上的表现都优于其在稀疏数据集上的表现。GPU模型在数据集 Last.FM 上表现最好,大幅超越了其他模型。在交互数据较少的情况下,模型对于节点特征的构建不够充分,知识图谱中的实体能够帮助模型缓解数据稀疏和冷启动问题,此时挖掘实体中的知识特征对提升推荐性能有很大帮助。在相对密集的数据集 MovieLens 上,GPU 也有最好的性能,说明当交互数据较多时,充分地挖掘交互数据中的交互特征对于节点特征向量的构建最为重要。GPU 迭代聚合用户物品交互图上的领域信息来构建用户及物品高阶的交互信息,能够更好地细化用户及物品的表示,促进了推荐性能。

## 5 结束语

当前基于知识图谱的推荐方法大都专注于利用 KG 来构建用户及物品的特征表示,忽略了对用户交互信息的有效利用。本文提出了一种推荐模型 GPU,同时利用了来自两个图的结构信息。GPU 由两个主要模块组成:一个是交互传播模块,使用 GNN 通过迭代聚合 UIG 上邻居节点向量来更新当前节点的特征表示;二是知识传播模块,对传播得到的多层知识关联进行编码,丰富了项目的特征表示。在两个公开可用的真实数据集上的实验结果证实,本文提出的 GPU 模型在推荐效果和泛化能力方面优于竞争基线。

## 参考文献

[1] SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms [C]//Proceedings of the 10<sup>th</sup> International Conference on World Wide Web. 2001: 285-295.

[2] SCHEIN A I, POPESCU A, UNGAR L H, et al. Methods and metrics for cold-start recommendations [C]//Proceedings of the 25<sup>th</sup> Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. 2002: 253-260.

[3] HUI B, ZHANG L, ZHOU X, et al. Personalized recommendation system based on knowledge embedding and historical behavior [J]. Applied Intelligence, 2022, 52(1): 954-966.

[4] WANG H, ZHANG F, WANG J, et al. RippletNet: Propagating

user preferences on the knowledge graph for recommender systems [C]//Proceedings of the 27<sup>th</sup> ACM International Conference on Information and Knowledge Management. 2018: 417-426.

[5] WANG Z, LIN G, TAN H, et al. CKAN: collaborative knowledge-aware attentive network for recommender systems [C]//Proceedings of the 43<sup>rd</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020: 219-228.

[6] WANG X, HE X, CAO Y, et al. Kgat: Knowledge graph attention network for recommendation [C]//Proceedings of the 25<sup>th</sup> ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2019: 950-958.

[7] GORI M, MONFARDINI G, SCARSELLI F. A new model for learning in graph domains [C]//Proceedings of 2005 IEEE International Joint Conference on Neural Networks. IEEE, 2005: 729-734.

[8] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(1): 4-24.

[9] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [C]//Proceedings of the World Wide Web Conference. 2019: 3307-3313.

[10] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering [C]//Proceedings of the 42<sup>nd</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019: 165-174.

[11] HE X, DENG K, WANG X, et al. Lightgcn: Simplifying and powering graph convolution network for recommendation [C]//Proceedings of the 43<sup>rd</sup> International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020: 639-648.

[12] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs [J]. Advances in Neural Information Processing Systems, 2017, 30: 1024-1034.

[13] ZHANG L, KANG Z, SUN X, et al. KCRec: Knowledge-aware representation graph convolutional network for recommendation [J]. Knowledge-Based Systems, 2021, 230: 107399.

[14] DONG C, JU X, MA Y. HRS: Hybrid recommendation system based on attention mechanism and knowledge graph embedding [C]//Proceedings of IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology. 2021: 406-413.

[15] YANG Z, CHENG J. Recommendation algorithm based on knowledge graph to propagate user preference [J]. International Journal of Computational Intelligence Systems, 2021, 14(1): 1564-1576.

[16] QIAN F, ZHU Y, CHEN H, et al. Reduce unrelated knowledge through attribute collaborative signal for knowledge graph recommendation [J]. Expert Systems with Applications, 2022, 201: 117078.