

## 引文格式:

刘天航, 杨晓雪, 周慧, 等. 基于图神经网络的协同过滤推荐算法综述 [J]. 集成技术, 2024, 13(4): 1-15.

Liu TH, Yang XX, Zhou H, et al. A survey of collaborative filtering recommender algorithms based on graph neural networks [J]. Journal of Integration Technology, 2024, 13(4): 1-15.

## 基于图神经网络的协同过滤推荐算法综述

刘天航 杨晓雪 周慧 赵中英\*

(山东科技大学计算机科学与工程学院 青岛 266590)

**摘要** 推荐系统因可有效解决信息过载问题而受到学术界与工业界的广泛关注。基于图神经网络的协同过滤推荐算法可有效表征用户和项目特征, 并可学习用户和项目间的复杂关系, 成为近年来推荐系统中广泛使用的一种技术。作者首先根据拟解决问题的不同对算法进行分类, 然后对每个类别下的代表性算法进行比较与分析; 其次, 对实验中常用的数据集进行分类汇总, 并对常用的评价指标进行简要介绍; 最后, 给出该领域面临的挑战和未来可能的研究方向。

**关键词** 推荐系统; 协同过滤; 图神经网络

中图分类号 TP391 文献标志码 A doi: 10.12146/j.issn.2095-3135.20230731001

### A Survey of Collaborative Filtering Recommender Algorithms Based on Graph Neural Networks

LIU Tianhang YANG Xiaoxue ZHOU Hui ZHAO Zhongying\*

(College of Computer Science and Engineering, Shandong University of Science and Technology, Qingdao 266590, China)

\*Corresponding Author: zzyu@163.com

**Abstract** Recommendation system can effectively address the problem of information overload, attracting extensive attention from both academia and industry. Collaborative filtering recommender algorithms based on graph neural networks have emerged as a widely adopted technique in recent years. These algorithms can effectively represent user and item features and learn intricate relationships between users and items. Therefore, they have become prevalent in the field of recommendation system. Firstly, the paper categorizes the algorithms based on the problems that they aim to solve and then provides a comparison and analysis of representative algorithms within each category. The paper also summarize commonly used datasets in experiments and briefly introduce the key evaluation metrics. Finally, the paper discuss the challenges and potential research directions.

收稿日期: 2023-07-31 修回日期: 2023-11-27

基金项目: 国家自然科学基金项目 (62072288); 山东省自然科学基金项目 (ZR2022MF268)

作者简介: 刘天航, 硕士研究生, 研究方向为推荐系统; 杨晓雪, 硕士研究生, 研究方向为动态图神经网络; 周慧, 博士, 研究方向为图神经网络、推荐算法; 赵中英 (通讯作者), 教授, 研究方向为图数据挖掘、推荐算法、人工智能, E-mail: zzyu@163.com。

**Keywords** recommendation system; collaborative filtering; graph neural network

**Funding** This work is supported by National Natural Science Foundation of China (62072288), Natural Science Foundation of Shandong Province (ZR2022MF268)

## 1 引 言

随着互联网和信息技术的发展,数据呈现爆炸式增长,高度信息化的大数据时代由此到来。丰富的信息资源极大程度地满足了人们日常工作和生活的需求,但也不可避免地导致信息过载问题。在此背景下,如何满足用户的个性化需求成为一项重大挑战。推荐系统应运而生,并得到快速发展,且在提高用户体验、促进销售等方面起重要作用。近年来,推荐系统已广泛应用于各种互联网场景中,如商品推荐<sup>[1]</sup>、兴趣点推荐<sup>[2]</sup>、新闻推荐<sup>[3]</sup>等。

推荐系统的发展历程可分为 3 个阶段:浅层模型<sup>[4-7]</sup>、神经网络模型<sup>[8-9]</sup>和基于图神经网络的模型。传统的推荐模型通过计算用户和项目间的相似度捕捉协同过滤效应,但不能捕捉用户和项目的特征信息。为此,某些研究者提出基于浅层模型的协同过滤方法,将推荐问题转化为用户和项目的表示学习问题,如因子分解机<sup>[7]</sup>和矩阵分解<sup>[4]</sup>。但是,基于浅层模型的协同过滤方法难以捕捉用户行为数据中蕴含的丰富信息。因此,研究者进一步提出基于神经网络的模型,利用深度学习技术提高推荐系统的表达能力。例如,通过使用多层感知机扩展矩阵分解的内积,或采用深度因子分解机<sup>[10]</sup>将浅层因子分解机<sup>[7]</sup>与多层感知机相结合。然而,基于神经网络的模型在训练和预测过程中忽略了用户和项目交互数据中的高阶结构信息。近几年,图神经网络的发展为推荐系统解决上述问题提供了思路。图神经网络利用图结构表示用户和项目间的关系,并通过消息传递机制生成目标节点的特征信息,从而使每个节点

都可汇聚其高阶邻居的信息。图神经网络凭借其在处理结构数据和探索结构信息方面的优势,已成为推荐系统中最有效的方法之一。

推荐系统虽然受到学术界与工业界的广泛关注,但是其在实际应用中仍然存在以下亟待解决的问题。

(1)冷启动问题<sup>[11]</sup>:推荐系统在初始阶段对于新加入的用户或项目没有足够的历史交互数据或者特征信息,这使得推荐系统无法进行准确的个性化推荐。

(2)数据稀疏问题<sup>[12]</sup>:用户和项目间的交互行为非常少,导致推荐系统难以准确预测用户对未见过项目的喜好程度。数据稀疏会影响推荐结果的准确率和召回率,造成推荐系统效果不佳的问题。

(3)鲁棒性问题<sup>[13]</sup>:该问题指推荐系统对各种不确定性因素和异常情况的适应能力。它关注推荐系统在面对数据噪声、系统故障、攻击行为、数据偏差等不确定性和异常情况时的表现和稳定性。

(4)过平滑问题<sup>[14]</sup>:在信息汇聚过程中,随着层数的增加,图神经网络的节点特征变得非常相似,最终导致推荐结果过于一致或缺乏个性化。原因是没有共同兴趣的高阶相邻用户也参与图卷积运算,导致没有共同兴趣的用户获得相似的嵌入表示。

针对上述问题,国内外研究者通过探索不同的解决思路,提出大量算法,并对相关工作进行分类梳理,有助于读者快速了解和掌握该领域的最新学术思想和动态。本文第 2 节介绍相关概念,第 3 节比较分析代表性算法,第 4 节汇总推

荐系统领域中的常用数据集, 并进行了算法性能比较, 第 5 节对基于图神经网络的协同过滤推荐算法进行了总结与展望。

## 2 相关概念

图通常表示为  $G=(V,E)$ 。其中,  $V$  为图中节点的集合;  $E$  为图中边的集合。令  $v_i \in V$  和  $v_j \in V$  表示两个节点,  $e_{ij}=(v_i, v_j) \in E$  表示连接  $v_i$  和  $v_j$  的一条边。节点  $v$  的邻居节点集合表示为  $N(v)=\{u \in V | (v, u) \in E\}$ 。图大致可分为以下几类。

(1) 有向图/无向图: 有向图是所有边从一个节点指向另一个节点的图。无向图是有向图的一个特例。其中, 如果两个节点相连, 则存在一对方向相反的边。

(2) 同质图/异质图: 同质图由一种类型的节点和边组成, 而异质图由两种及以上的节点和边组成。

(3) 超图: 图的一种推广, 一条边可连接多个节点。

学习域: 图神经网络利用两种模型表示学习——谱域模型和空间域模型。

(1) 谱域模型: 谱域模型是基于图信号处理和谱图论的概念。它的核心思想是通过对图的拉普拉斯矩阵进行特征分解, 将图的信息转换到特征空间中。拉普拉斯矩阵编码图的结构和拓扑信息, 它的特征向量对应图的频谱, 类似于频域信号分析。

(2) 空间域模型: 空间域模型直接在原始图结构上进行图表示学习, 不需要显式地进行特征分解, 通常定义一些局部邻域聚合规则, 可通过在节点的邻居上进行信息聚合来更新节点的表示。

图神经网络: 近年来, 图神经网络在处理大规模图数据和进行图的特征提取方面展示出巨大的潜能, 并已成功应用于节点分类<sup>[15]</sup>、节点聚类<sup>[16]</sup>、链路检测<sup>[17]</sup>等复杂网络任务中。图神

神经网络<sup>[18-22]</sup>的主要思想是迭代地聚合来自邻居节点的特征信息, 并在传播过程中将聚合的邻居信息与当前中心节点的特征表示进行融合。图神经网络可堆叠由聚合操作 (Aggregation) 和更新操作 (Update) 组成的多个传播层, 如公式 (1) 和公式 (2) 所示。

$$Aggregation: n_v^{(l)} = Aggregator_l \left( \left\{ h_u^{(l)}, \forall u \in N_{(v)} \right\} \right) \quad (1)$$

$$Update: h_v^{(l+1)} = Updater_l \left( h_v^{(l)}, n_v^{(l)} \right) \quad (2)$$

其中,  $n_v^{(l)}$  为  $v$  的邻居节点聚合后的表示;  $h_u^{(l)}$  为节点  $u$  在  $l$  层的表示;  $Aggregation_l$  为第  $l$  层聚合操作的函数;  $Update_l$  为第  $l$  层更新操作的函数。

## 3 基于图神经网络的协同过滤推荐算法

本文设计了一个统一的框架, 如图 1 所示, 首先, 该框架根据推荐算法面向的不同问题类型将推荐算法分为 4 大类: 面向冷启动问题、面向数据稀疏问题、面向鲁棒性问题和面向过平滑问题。然后, 在每个类别下, 根据图结构进一步划分为基于原始用户项目二分图和基于增强用户项目二分图两个子类。下文将对每个类别下的代表性算法思路和技术进行比较与分析。

### 3.1 面向冷启动问题

#### 3.1.1 基于原始用户项目二分图的算法

Berg 等<sup>[23]</sup>提出的图卷积矩阵补全 (graph convolutional matrix completion, GCMC) 算法是较早将图卷积用于推荐系统的算法。矩阵补全是推荐系统的一个子任务, GCMC 算法将矩阵补全视为用户项目二分图上的链路预测问题, 并将图卷积操作融入自编码器结构中。自动编码器在二分交互图上传递消息, 以产生用户和项目节点的潜在表示, 并将这些潜在表示输入双线性解码器, 以重建评级链接。当用户项目二分图伴随诸如社交网络之类的结构化外部信息时, 将矩阵补全公式化为二分图上的链接预测任务的优势变得

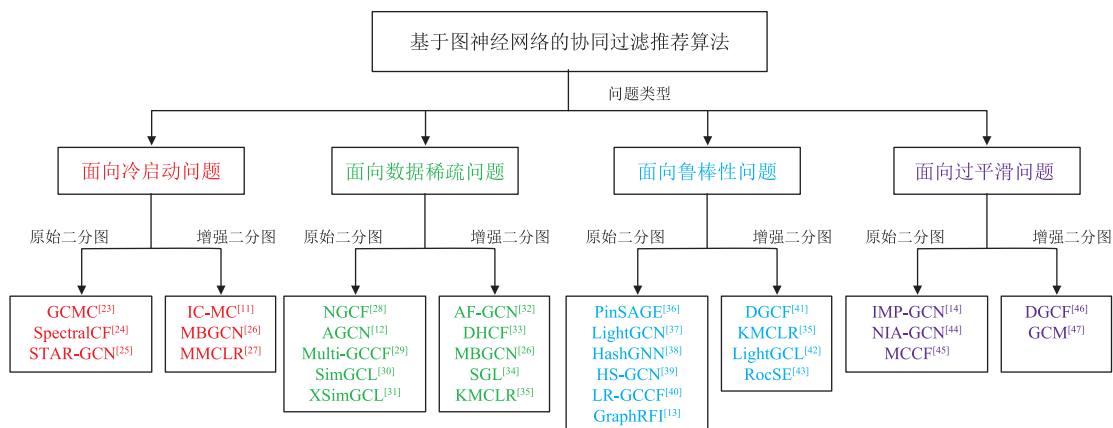


图1 算法分类框架

Fig. 1 The classification framework for the algorithms

极为突出。这种外部信息与交互数据相结合的方法可突破与冷启动问题相关的性能瓶颈。

GCMC 仅考虑用户(或项目)的一阶邻居,未考虑用户和项目间的高阶关系。如图2所示,如果用户  $u_1$  和用户  $u_2$  通过项目  $i_2$  连接,那么,  $u_2$  可被认为是用户  $u_1$  的相似用户。将  $u_2$  喜欢的项目  $i_6$  和  $i_7$  推荐给  $u_1$  的过程就是利用用户和项目间的高阶关系信息进行项目推荐。




图2 用户和项目的高阶关系

Fig. 2 The high level relationships between users and items

Zheng 等<sup>[24]</sup>进一步提出谱域协同过滤(spectral collaborative filtering, SpectralCF)算法。该算法首先将用户和项目之间的关系转化为二分图,然后基于二分图在谱域中执行谱卷积运

算,并动态调整推荐系统的每个频域的重要性。此过程不仅可有效利用图的邻近信息,还可捕获谱域中存在的丰富连通性信息。SpectralCF 算法可发现用户和项目间的深层连接,因此缓解了协同过滤算法的冷启动问题。但是,随着层数的增多,算法会面临过平滑问题。

在一定条件下,矩阵补全和谱卷积运算的空间复杂性很高。因此,Zhang 等<sup>[25]</sup>提出堆叠和重构图卷积网络(stacked and reconstructed graph convolutional networks for recommender systems, STAR-GCN)算法。该算法采用多个图卷积网络(graph convolutional network, GCN)编码器-解码器,并通过结合中间监督提高最终预测性能。与具有一个 one-hot 编码输入的图卷积矩阵完成模型不同,STAR-GCN 将学习到的低维用户和项目潜在表示作为输入,以抑制模型空间的复杂性。此外,STAR-GCN 可通过重建屏蔽输入节点嵌入为新节点生成节点嵌入,可基本解决冷启动问题。同样,堆叠多层 GCN 也会面临过平滑问题。

### 3.1.2 基于增强用户项目二分图的方法

Zhang 等<sup>[11]</sup>提出基于图神经网络的归纳矩阵补全(inductive matrix completion based on graph neural networks, IC-MC)算法。该算法不使用边信息即可完成矩阵补全任务,它通过从评级矩阵



中生成(用户, 项目)一阶子图训练图神经网络, 并将这些子图映射到它们相应的评级。IC-MC 是归纳性的, 可推广至训练期间看不见的用户和项目, 很好地缓解了协同过滤算法的冷启动问题。但是, 不使用边信息可能会导致重要信息的丢失。

上述单行为推荐算法不利于捕获用户更多的兴趣偏好。因此, Jin 等<sup>[26]</sup>提出多行为推荐图卷积神经网络(multi-behavior recommendation with graph convolutional networks, MBGCN)算法。MBGCN 算法有一个基于项目的评分模块, 该模块将目标项目与用户互动过的项目进行比较, 以评估目标项目。当新用户进入时, 这种设计可在不重新训练模型的情况下解决冷启动问题, 提高了用户在每个维度上的嵌入为 0 时的推荐有效性。但是, 多行为会比单行为的参数量大得多, 导致计算效率低。Wu 等<sup>[27]</sup>提出推荐中的多视角多行为对比学习(multi-view multi-behavior contrastive learning in recommendation, MMCLR)算法。MMCLR 算法在多行为用户项目交互二分图的基础上引入多行为用户交互项目的序列图。各行为用户项目交互图之间和各行为用户交互项目的序列图之间进行对比学习, 每种行为的交互图和用户交互项目的序列图之间进行对比学习。MMCLR 算法通过上述两种对比学习任务充分利用多行为、多视图的信息, 缓解了冷启动问题。但是, 多个对比学习任务的收敛速度可能不一

致, 算法会被损失函数大的任务主导, 不利于提高推荐效果。

本文进一步将本节介绍的算法进行综合比较与分析, 其中, MMCLR 算法是目前性能最优的算法, 如表 1 所示。

### 3.2 面向数据稀疏问题

#### 3.2.1 基于原始用户项目二分图的算法

Wang 等<sup>[28]</sup>提出图神经协同过滤(neural graph collaborative filtering, NGCF)算法, 利用用户项目间的高阶关系解决数据稀疏问题。该算法由嵌入层、嵌入传播层和预测层 3 部分组成。

(1)在嵌入层中, 通过输入用户和项目交互的数据, 可建立参数矩阵。该参数矩阵可视作嵌入查找表。与传统的矩阵补全方法和神经协同过滤方法不同, 该算法可在推荐中生成更有效的嵌入。

(2)在嵌入传播层中, 可通过聚合用户(或项目)的嵌入细化项目(或用户)的嵌入, 在聚合每层邻居时, 将上一层邻居节点向量和中心节点向量的哈达玛积作为中心节点和邻居的相似性度量。通过堆叠多个传播层可探索高阶连通性信息, 这些信息是至关重要的协同信号, 会对计算用户和项目之间的相关性得分产生重要影响。

(3)在预测层中, 将多个嵌入传播层获得的表示串联起来, 得到最终的用户和项目表示。最后将用户和项目的表示直接做内积, 得到最终的预测值。

该模型的关键是通过提出一种嵌入传播层促

表 1 面向冷启动问题的算法综合比较

Table 1 The comprehensive comparison of algorithms for cold start problem

解决的问题	算法	理论方法	优点	缺点
冷启动问题	GCMC <sup>[23]</sup>	矩阵补全	可将外部信息与交互数据相结合	忽略了高阶邻居信息
	SpectralCF <sup>[24]</sup>	谱域协同过滤	揭示谱域中存在的丰富连通性信息	面临过平滑问题
	STAR-GCN <sup>[25]</sup>	堆叠重构 GCN	模型空间复杂性小	多层 GCN 可能会面临过平滑问题
	IC-MC <sup>[11]</sup>	归纳矩阵补全	可推广到训练期间看不到的用户和项目	不使用边信息可能会丢失重要的信息
	MBGCN <sup>[26]</sup>	项目评分模块	可在不重新训练模型的情况下为新用户推荐	模型参数量大, 效率低
	MMCLR <sup>[27]</sup>	多视角多行为对比学习	多行为图和交互项目序列图可捕捉用户更精确的兴趣偏好	多 CL 任务收敛速度可能不一致, 或者模型会被损失比较大的任务主导

使用户和项目之间更深的交互，从而捕获两者之间更多的协同信息。但是，算法中的特征转换和激活函数可能会对推荐产生不好的影响。

节点属性值是节点蕴含的重要信息，考虑属性值可有效缓解数据稀疏问题。因此，Wu等<sup>[12]</sup>提出联合项目推荐和属性推理(joint item recommendation and attribute inference: an adaptive graph convolutional network approach, AGCN)算法。该算法利用用户和项目的属性值缓解数据稀疏问题。AGCN算法通过先前学习的近似属性值学习图嵌入参数，然后将经过图学习模块得到的属性值发送回属性图，以此更新属性值。但是，推理得到的属性值不一定适合用户和项目。

除了节点属性外，用户之间和项目之间还包含了很多重要信息。Sun等<sup>[29]</sup>提出的多图卷积协同过滤(multi-graph convolution collaborative filtering, Multi-GCCF)算法可通过一个多图编码层有效解决数据稀疏问题。该多图编码层构造了用户-用户、项目-项目两个额外的图，并应用图卷积学习为目标用户节点和项目节点生成额外的嵌入，以捕捉用户和项目之间的相似信息，这种相似信息可弥补稀疏的用户-项目交互数据。

对比学习从原始数据中提取自监督信号的能力与推荐系统解决数据稀疏性问题的需求

非常一致。因此，Yu等<sup>[30]</sup>提出用于推荐的简单图对比学习(simple graph contrastive learning for recommendation, SimGCL)算法，其框架如图3(a)所示。Wu等<sup>[34]</sup>提出用于推荐的自监督图学习(self-supervised graph learning for recommendation, SGL)算法。虽然它们都是利用对比学习技术缓解数据稀疏问题，但是SimGCL算法没有对图进行增强操作，SGL算法则对图进行了增强操作。SGL算法将在3.2.2节讲述。SimGCL算法认为图扩充是没有必要的，反而破坏了语义结构。因此，该算法在每层GCN输出后添加随机均匀噪声，然后将添加不同噪声学习到的最终表示进行对比学习。但是，该算法的时间复杂度很高，是传统推荐模型的近3倍。

在SimGCL算法基础上，Yu等<sup>[31]</sup>又提出面向推荐的极简单图对比学习(towards extremely simple graph contrastive learning for recommendation, XSimGCL)算法，其框架如图3(b)所示。该算法将推荐任务和对比学习任务进行结合，在每层GCN的输出表示中添加噪声，让最终输出表示和某一层添加噪声后的输出表示进行对比学习。XSimGCL简化了SimGCL，但是无法解释添加随机噪声能提高推荐准确率的原因。

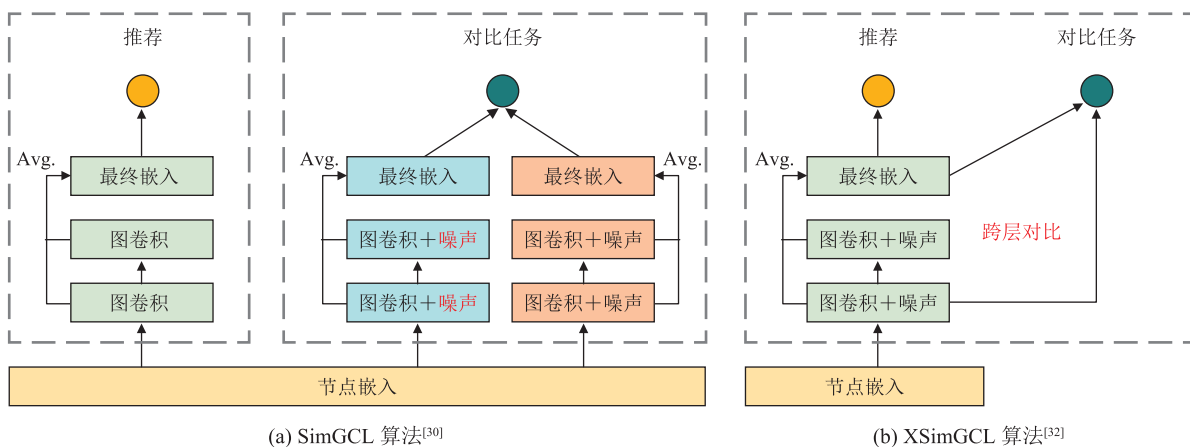


图3 SimGCL算法和XSimGCL算法框架

Fig. 3 The framework of SimGCL algorithm and XSimGCL algorithm

### 3.2.2 基于增强用户项目二分图的算法

为解决数据稀疏问题, Yue 等<sup>[32]</sup>提出属性融合图卷积(attribute-fusing graph convolution network for recommendation, AF-GCN)算法。AF-GCN 算法不仅可有效利用节点的属性信息, 还可缓解数据稀疏问题。AF-GCN 算法不是简单地利用用户-项目交互图, 而是将用户和项目节点属性作为新节点添加到交互图上, 并与原节点相连接。然后, 基于 AF-GCN 算法设计了一个基于注意力的属性融合机制, 该机制将每个用户和项目的多维属性表示组合成一个复合属性表示, 生成一个新的用户-项目交互图。最后, 在新图上执行图卷积操作。但是, 属性中可能会有噪声信息。

与 NGCF 算法相似, Ji 等<sup>[33]</sup>提出的双通道超图协同过滤(dual channel hypergraph collaborative filtering, DHCF)算法也是通过捕获用户和项目的高阶关系解决数据稀疏问题。该算法引入双通道学习策略, 在通道内部学习时, 采用超图结构对具有显式混合高阶相关性的用户和项目进行建模<sup>[48]</sup>, 通过设计跳跃超图卷积方法支持高阶相关性显式和高效的嵌入传播。但是, 超图卷积可能会引起不同关联规则定义的超边组的权重失衡。

在现实应用中, 仅利用目标行为不能更精准地捕获用户的兴趣偏好。因此, Jin 等<sup>[26]</sup>提出多行为推荐图卷积神经网络(multi-behavior recommendation with graph convolutional networks, MBGCN)算法, 不仅可解决冷启动问题, 还可缓解数据稀疏问题。该算法通过建立一个统一的异质图对研究的问题进行建模, 该异质图在目标行为交互图的基础上添加辅助行为的交互边。引入辅助行为的交互可有效缓解目标行为存在的数据稀疏问题。除此之外, MBGCN 算法还通过引入注意力机制进一步提高推荐性能。注意力机制可自动学习不同用户行为之间的重要性权重, 从而在用户行为图中更加关注重要的行为。这有助于减小稀疏数据对推荐结果的影

响, 并提高推荐的准确性。同 MBGCN 算法一样, Xuan 等<sup>[35]</sup>提出的多行为对比推荐的知识增强(knowledge enhancement for contrastive multi-behavior recommendation, KMCLR)算法也是建立一个异质图。除此之外, KMCLR 算法考虑到项目外部知识的丰富性, 还构建了一个项目-项目关系知识图。通过将多行为信息和知识图信息相结合, 可丰富用户和项目的信息。该算法强调从不同角度对用户-项目信息进行建模, 解决了目标行为的数据稀疏问题。但是, MBGCN 算法和 KMCLR 算法在引入额外信息的同时会引入噪声信号。

用于推荐的自监督图学习 SGL 算法<sup>[34]</sup>通过节点丢弃、边丢弃和随机游走方法生成新的对比视图。作为推荐的辅助任务, 自监督缓解了数据高度稀疏的问题。

笔者进一步将本节介绍的算法进行综合比较与分析, 其中, XSimGCL 算法和 KMCLR 算法是目前性能较优秀的两个算法, 如表 2 所示。

## 3.3 面向鲁棒性问题

### 3.3.1 基于原始用户项目二分图的算法

Ying 等<sup>[36]</sup>提出用于 web 级推荐系统的图卷积神经网络(graph convolutional neural networks for web-scale recommender systems, PinSAGE)算法。为应对大规模推荐系统的挑战, 该算法提出一种基于随机游走采样的训练方法。首先, 算法使用随机游走的方法从用户-项目交互图中生成路径, 然后通过最大化路径上的共现关系学习节点的嵌入表示。这两阶段的训练策略有助于提高节点表示的质量和推荐算法的鲁棒性。但是, 随机游走策略只利用图的连接信息, 未利用其他重要信息。

He 等<sup>[37]</sup>提出轻量化图卷积(simplifying and powering graph convolution network for recommendation, LightGCN)算法, 该算法通过消融实验证明 NGCF 算法中的特征线性转换和非

表2 面向数据稀疏问题的算法综合比较

Table 2 The comprehensive comparison of algorithms for data sparse problem

解决的问题	算法	理论方法	优点	缺点
数据稀疏问题	NGCF <sup>[28]</sup>	捕捉高阶关系	获得了用户和节点之间更多的协同关系	模型中的特征转换和非线性激活对推荐有害
	AGCN <sup>[12]</sup>	属性推理	节点表示根据属性更新不断优化	推理的属性不一定适合用户和项目
	Multi-GCCF <sup>[29]</sup>	多图编码器	多图卷积获得多个嵌入表示, 捕获用户和项目之前更多的相似信息	在捕获相似信息的同时可能会引入噪声
	SimGCL <sup>[30]</sup>	对比学习	对比视图保留了图原有的语义结构	计算成本是传统推荐模型的近 3 倍
	XSimGCL <sup>[31]</sup>	跨层对比学习	在 SimGCL 的基础上简化了对比学习的方式	添加随机噪声可解释性差
	AF-GCN <sup>[32]</sup>	属性融合	属性作为节点参与到图卷积运算中, 节点表示蕴含的信息更加丰富	可能会把属性中的噪声信息带入图卷积运算
	DHCF <sup>[33]</sup>	双通道超图卷积	双通道使嵌入传播更加高效	可能会引起不同关联规则定义的超边组的权重失衡
	MBGCN <sup>[26]</sup>	多行为	辅助行为捕获用户更精确的兴趣偏好	引入额外信息引起噪声信号问题
	KMCLR <sup>[35]</sup>	多行为对比学习	考虑了项目外部知识, 从不同角度对用户和项目建模	引入额外信息引起噪声信号问题
SGL <sup>[34]</sup>	对比学习	自监督解决了监督信号稀疏问题	无效的图扩充, 可解释性差	

线性激活函数对协同过滤产生了消极的影响, 因此在模型中去掉了上述两个冗余块。该算法由图卷积层、连接层和预测层 3 部分组成。

(1) 在图卷积层中, 与现存的大多数图卷积操作不同, 该算法丢弃了特征线性转换和非线性激活函数两个标准的 GCN 操作, 用户和项目在每一层只聚合它们的邻居, 不聚合目标节点本身。

(2) 在连接层中, 该算法仅使用简单的权重聚合, 将每一层得到的向量及原始向量连接起来, 并为每一层分配一个注意力(注意力设为  $1/(K+1)$ , 其中,  $K$  为层数), 得到最终的用户和项目表示。

(3) 在预测层中, 将用户和项目向量直接做内积, 得到最终的预测值。

总的来说, LightGCN 算法简化了标准 GCN, 获得了更好的表现。其在降低模型复杂度、提高计算效率方面很有优势, 更易于训练, 有更好的鲁棒性。

传统的基于内容的推荐系统使用哈希技术减少检索空间和存储空间, 但是这种方法存在两个主要问题: 哈希冲突和哈希表过大, 限制

了推荐系统的可扩展性。Tan 等<sup>[38]</sup>提出推荐系统的图神经网络哈希学习 (learning to Hash with graph neural networks for recommender systems, HashGNN) 算法, 使用哈希函数将用户和物品的原始特征表示映射到二进制哈希向量上, 从而将原始连续型特征转换成离散的二进制特征。这种方式可有效减少模型的参数数量, 提高模型的计算效率, 同时可增强算法的鲁棒性, 减少对输入数据的敏感度, 降低模型出现过拟合的风险。但是, 该算法忽略了高阶信息。为在使用哈希技术的同时不忽略高阶信息, Liu 等<sup>[39]</sup>提出用于推荐的 Hamming 空间图卷积网络 (Hamming spatial graph convolutional networks for recommendation, HS-GCN) 算法, 通过在 Hamming 空间上定义特征距离度量提高推荐系统的鲁棒性。具体来说, 该算法首先将用户和物品的特征向量表示为二进制哈希码, 并在 Hamming 空间上计算它们之间的距离; 其次, 通过定义一个基于距离度量的 Hamming 空间图, 利用 Hamming 空间的局部结构和全局结构进行图卷积运算; 最后, 利用学习到的模型进行推荐。与传统的基于欧几里得空



间的方法相比, 该方法可更好地处理数据中的异常和噪声, 从而提高推荐系统的鲁棒性。但是, HashGNN 和 HS-GCN 算法均不可避免地丢失了重要信息。

为避免信息丢失, Chen 等<sup>[40]</sup>提出线性残差图卷积网络 (revisiting graph based collaborative filtering: a linear residual graph convolutional network approach, LR-GCCF) 算法, 使用线性残差图卷积网络学习用户和项目的关系, 其中的每个卷积层都使用线性残差增强模型的表达能力。该方法可避免信息在网络中丢失或扭曲, 有效提高了推荐算法的鲁棒性。

除了保留重要信息外, 检测恶意用户的虚假反馈也是一种提高鲁棒性的方法。Zhang 等<sup>[13]</sup>提出一种基于 GCN 的端到端的统一学习框架 (GCN-based user representation learning for unifying robust recommendation and fraudster detection, GraphRFI) 算法, 执行推荐与欺诈检测两种任务。在其端到端的学习过程中, 用户在欺诈者检测组件中被视为欺诈者的概率可自动确定该用户的评级数据在推荐组件中的贡献; 而在推荐组件中输出的预测误差充当欺诈者检测组件中的重要特征。这两个组件可相互增强, 即使存在先令攻击, 也能产生稳定推荐。

### 3.3.2 基于增强用户项目二分图的算法

Liu 等<sup>[41]</sup>提出的去振荡自适应图协同过滤 (deoscillated adaptive graph collaborative filtering, DGCF) 算法证明 GCN 通过堆叠多个聚合层传播高阶信号存在 3 个弊端: 振荡问题、二分图的变局部性和固定的传播模式问题。上述弊端破坏了多层结构传播信息的能力, 降低了模型的鲁棒性。为解决上述弊端, 该算法设计了一个跨跳传播层和一个自适应层。跨跳传播层直接和间接传播邻居节点的信息, 解决振荡问题和二分图的变局部性。但是, 跨跳传播会破坏图的语义结构。在跨跳传播层之前加一个自适应层, 可自适应地

控制每个节点的传播过程。

KMCLR 算法<sup>[35]</sup>通过引入项目-项目关系知识图缓解目标行为数据稀疏问题。虽然附加的辅助信息有利于提高推荐性能, 但也会引入噪声信号。因此, 在使用辅助信息进行信息增强的同时, 还要考虑算法因为噪声数据带来的鲁棒性问题。具体来说, 多行为交互图通过设置一系列随机丢弃概率探索最优采样策略; 知识图通过调整采样公式中的间隔参数实现知识图的自动降噪采样。

尽管对比学习在处理高度稀疏的数据方面取得了成功, 但大多数现有的图对比学习方法要么对用户-项目交互图执行随机增强 (如节点/边缘扰动), 要么依赖于基于启发式的增强技术 (如用户聚类) 生成对比视图, 不能很好地保留固有的语义结构, 并且很容易受噪声扰动的影响, 降低了模型的鲁棒性。Cai 等<sup>[42]</sup>提出的用于推荐的简单而有效的图对比学习 (simple yet effective graph contrastive learning for recommendation, LightGCL) 算法利用奇异值分解进行对比增强。该算法可使全局协作关系进行无约束的结构精化, 不仅很好地保留了固有语义结构, 而且没有噪声引入, 提高了基于图对比学习的推荐算法的通用性和鲁棒性。但是, LightGCL 算法还是会面临数据增强操作带来的混杂效应。

除了进行没有噪声引入的数据增强外, Ye 等<sup>[43]</sup>还提出基于结构去噪和嵌入扰动的鲁棒图神经协同过滤 (towards robust neural graph collaborative filtering via structure denoising and embedding perturbation, RocSE) 算法。首先, 该算法通过计算邻域相似性捕获更相关的交互, 从而对图结构进行去噪处理。然后, 该算法通过对抗性攻击操作, 在嵌入空间中引入分布内扰动, 并进一步利用对比学习约束用户和项目的嵌入, 以提高模型的鲁棒性。但是, 引入嵌入扰动会破坏图的语义结构。

本文进一步将本节介绍的算法进行综合比较

与分析,其中, KMCLR 算法和 LightGCL 算法是目前性能较优秀的两个算法,如表 3 所示。

### 3.4 面向过平滑问题

#### 3.4.1 基于原始用户项目二分图的算法

Liu 等<sup>[14]</sup>提出兴趣感知消息传递图卷积(interest-aware message-passing GCN for recommendation, IMP-GCN)算法。该算法仅在一阶图卷积时用整个二分图,随后的高阶图卷积未用整个图,而是设计一个无监督的子图生成模块,并利用该模块生成具有相似兴趣的用户及其交互项的子图,然后在每个子图上执行图卷积操作。通过引入兴趣子图卷积,该算法能有效解决推荐系统中的过度平滑问题。但是,划分子图会破坏图的完整性,使数据更加稀疏。

为更精确地区分用户偏好,并避免重要信息和特征的丢失, Sun 等<sup>[44]</sup>提出用于推荐的邻居交互感知图卷积网络(neighbor interaction aware graph convolution networks for recommendation, NIA-GCN)算法。该算法引入一种新的邻居交互聚合模块,与传统的 GCN 算法直接聚集来自相邻节点的信息不同,它只捕获目标节点与其邻居之间的成对交互。通过结合邻居交互机制, NIA-GCN 算法可提高推荐算法的表达力,使它们

有效捕获局部和全局信息。该算法通过保留重要特征和避免图卷积过程中信息的丢失缓解过平滑问题,提高推荐系统的性能。但是, NIA-GCN 算法的聚合模块实现复杂,可解释性较差。

除了捕获局部和全局信息外,交互数据的不同特征也非常重要。因此, Wang 等<sup>[45]</sup>提出多分量图卷积协同过滤(multi-component graph convolutional collaborative filtering, MCCF)算法。MCCF 算法将用户-项目交互数据表示为多个组件图,每个组件图捕捉数据的不同特征或层次信息。为将不同组件图的节点表示进行融合,可使用一个注意力机制学习每个嵌入向量的权重,以得到最终的节点表示。为进一步解决过平滑问题, MCCF 算法提出组件选择机制,通过引入一个注意力模块动态选择每个用户-项目对中最具区分性的组件图进行表示学习。但是,多组件网络使算法变得复杂,不容易理解和解释。

#### 3.4.2 基于增强用户项目二分图的算法

Wang 等<sup>[46]</sup>提出的解耦图协同过滤(disentangled graph collaborative filtering, DGCF)算法把用户和项目的节点表示解耦,将它们分解为内容表示和连接表示。内容表示捕捉节点的内部特征,连接表示捕捉节点之间的关系。该算法

表 3 面向鲁棒性问题的算法综合比较

Table 3 The comprehensive comparison of algorithms for robustness problem

解决的问题	算法	理论方法	优点	缺点
鲁棒性问题	PinSAGE <sup>[36]</sup>	随机游走策略	训练模型快	只利用了用户和项目的连接信息
	LightGCN <sup>[37]</sup>	简化 GCN	模型简单,训练速度快	面临过平滑问题
	HashGNN <sup>[38]</sup>	哈希学习	参数量小,效率高	忽略高阶信息
	HS-GCN <sup>[39]</sup>	Hamming 空间 GCN	Hamming 空间比欧几里得空间更容易处理数据中的异常情况	忽略图的语义信息,基于哈希的推荐解释性差
	LR-GCCF <sup>[40]</sup>	残差 GCN	残差机制避免信息丢失	面临过平滑问题
	GraphRFI <sup>[13]</sup>	欺诈检测	可检测恶意用户的虚假反馈	欺诈检测存在不公平性问题
	DGCF <sup>[41]</sup>	去振荡自适应	稳定的 GCN 传播过程	跨跳邻居传播破坏图中固有的语义结构
	KMCLR <sup>[35]</sup>	随机丢弃,降噪	可自动对噪声数据进行降噪	自动降噪的同时可能会丢弃重要信息
	LightGCL <sup>[42]</sup>	奇异值分解对比学习	与节点/边缘扰动的增强方式相比,可较好地保留固有语义结构	数据增强带来混杂效应
	RocSE <sup>[43]</sup>	结构去噪和嵌入扰动	两组件互相约束,模型稳定	破坏图的语义结构

还通过引入门控机制将内容表示和连接表示融合起来, 以生成最终的节点表示。这种解耦和融合机制可更好地捕捉节点中蕴含的丰富多样的信息, 从而可缓解过平滑问题。但是, 分解节点表示可能会丢失重要的关联信息。

为捕获更多的关联性, Wu 等<sup>[47]</sup>提出用于上下文感知推荐系统的图卷积机 (graph convolution machine for context-aware recommender system, GCM) 算法。该算法通过引入上下文信息扩展传统的用户-物品交互图, 使得模型可从上下文中获取更多的特征和关联性信息, 以此辅助推荐决策, 缓解因为高阶图卷积导致的过平滑问题。但是, 该算法在引入上下文的同时可能会引入噪声信息。

进一步将本节介绍的算法进行综合比较与分

析, 目前, 性能最优的算法是 IMP-GCN<sup>[14]</sup>, 如表 4 所示。

## 4 常用数据集与算法性能比较

### 4.1 常用数据集

目前, 在协同过滤推荐算法工作中, 常用数据集为用户数 (users)、项目数 (items)、交互数 (interactions)、链接 (link)、领域 (domain), 并可划分为用户行为 (user behavior) 和用户评分 (user rating) 两类, 如表 5 所示。

### 4.2 算法性能比较

本小节对标出的性能优秀的算法 (IMP-GCN、XSimGCL、LightGCL、MMCLR、KMCLR) 进行比较分析。目前, 在上述 5 个

表 4 面向过平滑问题的算法综合比较

Table 4 The comprehensive comparison of algorithms for oversmoothing problem

解决的问题	算法	理论方法	优点	缺点
过平滑问题	IMP-GCN <sup>[14]</sup>	兴趣子图卷积	考虑用户对不同兴趣的偏好	划分子图会破坏图的完整性, 使数据更加稀疏
	NIA-GCN <sup>[44]</sup>	邻居交互	有效捕获局部和全局信息	模型内部复杂, 可解释性差
	MCCF <sup>[45]</sup>	多分量图卷积	多个组件捕获数据的不同特征	多组件网络结构复杂, 算法内部运作不容易理解和解释
	DGCF <sup>[46]</sup>	节点表示解耦	解耦机制捕获节点的多样性和丰富性	分解节点表示可能会丢失重要的关联信息
	GCM <sup>[47]</sup>	上下文感知	捕获更多的关联性	可能会引入噪声信息

表 5 常用数据集介绍

Table 5 The descriptions of common datasets

类型	数据集	用户数量 (个)	项目数量 (个)	交互数量 (个)	领域	链接
用户行为	Gowalla	29 858	40 981	1 027 370	地理	<a href="https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/gowalla">https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/gowalla</a>
	Last.fm	1 892	17 632	92 834	音乐	<a href="https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/lastfm">https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/lastfm</a>
用户评分	Yelp2018	31 668	38 048	1 561 406	商户	<a href="https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/yelp2018">https://github.com/gusye1234/LightGCN-PyTorch/tree/master/data/yelp2018</a>
	Amazon-Book	52 643	91 599	2 984 108	书籍	
	Amazon-kindle Store	68 223	61 934	982 618	电子书	<a href="http://jmcauley.ucsd.edu/data/amazon">http://jmcauley.ucsd.edu/data/amazon</a>
	Amazon-Home&Kitchen	66 519	28 237	551 681	家居厨房	
	Netflix	480 189	17 770	100 480 507	电影	<a href="http://dataju.cn/Dataju/web/datasetInstanceDetail/32">http://dataju.cn/Dataju/web/datasetInstanceDetail/32</a>
	Movielens 1M	6 040	3 883	1 000 209	电影	<a href="http://files.grouplens.org/datasets/movielens/">http://files.grouplens.org/datasets/movielens/</a>
	Book-Crossing	278 858	271 379	1 149 780	书籍	<a href="http://www2.informatik.uni Freiburg.de/~cziegler/BX/">http://www2.informatik.uni Freiburg.de/~cziegler/BX/</a>
DoubanBook	13 024	22 347	792 062	书籍	<a href="https://doi.org/10.18170/DVN/LA9GRH">https://doi.org/10.18170/DVN/LA9GRH</a>	

性能优秀的算法中, IMP-GCN、XSimGCL、LightGCL 算法是单行为推荐, MMCLR、KMCLR 是多行为推荐。多行为推荐是在单行为推荐的基础上发展起来的, 单行为推荐仅利用目标行为的交互信息进行推荐, 而多行为推荐旨在利用辅助行为信息促进目标行为的推荐。多行为推荐普遍比单行为推荐的性能优秀。

在单行为推荐中, IMP-GCN 算法通过划分兴趣子图的方式更好地捕获用户的偏好兴趣, 但这种方式让本就稀疏的数据变得更加稀疏。因此限制 IMP-GCN 算法有更好的表现。XSimGCL 算法和 LightGCL 算法均通过图对比学习促进推荐性能的提高。XSimGCL 算法没有进行图扩充操作, 可较好地保留图的语义结构。但添加随机噪声会不可避免地引入噪声, 可能会限制推荐性能。然而, LightGCL 算法既能保留原始语义结构, 又能避免添加噪声, 还能缓解数据稀疏问题。所以, LightGCL 算法在单行为推荐中获得了最佳效果。在多行为推荐中, MMCLR 算法利用多行为、多视图信息促进目标行为的推荐。KMCLR 算法在考虑多行为的基础上还通过引入项目和项目关系知识图增强嵌入, 效果优于 MMCLR 算法。

## 5 总结与展望

作者分类介绍了基于图神经网络的协同过滤推荐算法, 并对各类别下的算法进行了比较。总的来说, 与传统的协同过滤算法相比, 基于图神经网络的算法更能充分挖掘用户和项目交互数据中的蕴含信息, 进而生成更准确的推荐结果。随着信息时代的发展, 用户对推荐结果的准确性和多样性也提出更高要求, 推荐系统面临挑战。未来可能的研究方向包括但不限于以下几个方面。

(1) 模型解释性: 提高图神经网络模型的可解释性是一个重要的研究方向。通过解释模型对

推荐结果的影响, 可提升用户对推荐结果的理解和信任度。

(2) 融合多样性: 传统的协同过滤方法倾向于推荐热门项目, 会导致推荐结果缺乏多样性。如何在图神经网络推荐模型中融入多样性考虑, 提供更加丰富和个性化的推荐结果, 是一个值得探索的方向。

(3) 隐私保护: 随着用户对隐私保护的关注度增加, 如何在图神经网络模型中充分考虑用户隐私, 并提供个性化的推荐服务, 是一个具有挑战性的研究方向。

(4) 跨领域推荐: 如何将图神经网络模型扩展到跨领域推荐系统中, 利用不同领域的信息进行推荐, 是未来的一个研究方向。例如, 结合社交网络、时空数据等多源信息进行跨领域推荐。

## 参 考 文 献

- [1] Liu WW, Zhang Y, Wang JL, et al. Item relationship graph neural networks for e-commerce [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(9): 4785-4799.
- [2] Chang B, Jang G, Kim S, et al. Learning graph-based geographical latent representation for point-of-interest recommendation [C] // Proceedings of the 29th ACM International Conference on Information & Knowledge Management, 2020: 135-144.
- [3] Hu LM, Xu SY, Li C, et al. Graph neural news recommendation with unsupervised preference disentanglement [C] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 4255-4264.
- [4] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30-37.
- [5] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback [C] // Proceedings of the 25th Conference



- on Uncertainty in Artificial Intelligence, 2009: 452-461.
- [6] Hsieh CK, Yang LQ, Cui Y, et al. Collaborative metric learning [C] // Proceedings of the 26th International Conference on World Wide Web, 2017: 193-201.
- [7] Rendle S. Factorization machines [C] // Proceedings of the 2010 IEEE International Conference on Data Mining, 2010: 995-1000.
- [8] He XN, Liao LZ, Zhang HW, et al. Neural collaborative filtering [C] // Proceedings of the 26th International Conference on World Wide Web, 2017: 173-182.
- [9] Tay Y, Tuan LA, Hui SC. Latent relational metric learning via memory-based attention for collaborative ranking [C] // Proceedings of the 2018 World Wide Web Conference, 2018: 729-739.
- [10] Guo HF, Tang RM, Ye YM, et al. DeepFM: a factorization-machine based neural network for CTR prediction [C] // Proceedings of the 26th International Joint Conference on Artificial Intelligence, 2017: 1725-1731.
- [11] Zhang MH, Chen YX. Inductive matrix completion based on graph neural networks [C] // Proceedings of the 8th International Conference on Learning Representations, 2020.
- [12] Wu L, Yang YH, Zhang K, et al. Joint item recommendation and attribute inference: an adaptive graph convolutional network approach [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 679-688.
- [13] Zhang SJ, Yin HZ, Chen T, et al. GCN-based user representation learning for unifying robust recommendation and fraudster detection [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 689-698.
- [14] Liu F, Cheng ZY, Zhu L, et al. Interest-aware message-passing GCN for recommendation [C] // Proceedings of the Web Conference, 2021: 1296-1305.
- [15] Kong XN, Yu PS, Ding Y, et al. Meta path-based collective classification in heterogeneous information networks [C] // Proceedings of the ACM International Conference on Information and Knowledge Management, 2012: 1567-1571.
- [16] Sun YZ, Norick B, Han JW, et al. Integrating meta-path selection with user-guided object clustering in heterogeneous information networks [C] // Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2012: 1348-1356.
- [17] Cao BK, Kong XN, Yu PS. Collective prediction of multiple types of links in heterogeneous information networks [C] // Proceedings of the 2014 IEEE International Conference on Data Mining, 2014: 50-59.
- [18] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks [C] // Proceedings of the 5th International Conference on Learning Representations, 2017.
- [19] Zhao ZY, Yang Z, Li C, et al. Dual feature interaction-based graph convolutional network [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 35(9): 9019-9030.
- [20] Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 1025-1035.
- [21] Velickovic P, Cucurull G, Casanova A, et al. Graph attention networks [C] // Proceedings of the 6th International Conference on Learning Representations, 2018.
- [22] Li YJ, Zemel L, Brockschmidt M, et al. Gated graph sequence neural networks [C] // Proceedings of the 4th International Conference on Learning Representations, 2016.
- [23] Berg RVD, Kipf TN, Welling M. Graph

- convolutional matrix completion [Z/OL]. arXiv Preprint, arXiv: 1706.02263, 2017.
- [24] Zheng L, Lu CT, Jiang F, et al. Spectral collaborative filtering [C] // Proceedings of the 12th ACM Conference on Recommender Systems, 2018: 311-319.
- [25] Zhang JN, Shi XJ, Zhao SL, et al. STAR-GCN: stacked and reconstructed graph convolutional networks for recommender systems [C] // Proceedings of the 28th International Joint Conference on Artificial Intelligence, 2019: 4264-4270.
- [26] Jin BW, Gao C, He XN, et al. Multi-behavior recommendation with graph convolutional networks [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 659-668.
- [27] Wu YQ, Xie RB, Zhu YC, et al. Multi-view multi-behavior contrastive learning in recommendation [C] // Proceedings of the 27th International Conference on Database Systems for Advanced Applications, 2022: 166-182.
- [28] Wang X, He XN, Wang M, et al. Neural graph collaborative filtering [C] // Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019: 165-174.
- [29] Sun JN, Zhang YX, Ma C, et al. Multi-graph convolution collaborative filtering [C] // Proceedings of the 2019 IEEE International Conference on Data Mining, 2019: 1306-1311.
- [30] Yu JL, Yin HZ, Xia X, et al. Are graph augmentations necessary? Simple graph contrastive learning for recommendation [C] // Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2022: 1294-1303.
- [31] Yu JL, Xia X, Chen T, et al. XSimGCL: towards extremely simple graph contrastive learning for recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(2): 913-926.
- [32] Yue GW, Xiao R, Zhao ZY, et al. AF-GCN: attribute-fusing graph convolution network for recommendation [J]. IEEE Transactions on Big Data, 2023, 9(2): 597-607.
- [33] Ji SY, Feng YF, Ji RR, et al. Dual channel hypergraph collaborative filtering [C] // Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2020: 2020-2029.
- [34] Wu JC, Wang X, Feng FL, et al. Self-supervised graph learning for recommendation [C] // Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2021: 726-735.
- [35] Xuan HR, Liu Y, Li BH, et al. Knowledge enhancement for contrastive multi-behavior recommendation [C] // Proceedings of the 16th ACM International Conference on Web Search and Data Mining, 2023: 195-203.
- [36] Ying R, He RN, Chen KF, et al. Graph convolutional neural networks for web-scale recommender systems [C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2018: 974-983.
- [37] He XN, Deng K, Wang X, et al. LightGCN: simplifying and powering graph convolution network for recommendation [C] // Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2020: 639-648.
- [38] Tan QY, Liu NH, Zhao X, et al. Learning to hash with graph neural networks for recommender systems [C] // Proceedings of the 29th International Conference on World Wide Web, 2020: 1988-1998.
- [39] Liu H, Wei YW, Yin JH, et al. HS-GCN: Hamming spatial graph convolutional networks

- for recommendation [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(6): 5977-5990.
- [40] Chen L, Wu L, Hong RC, et al. Revisiting graph based collaborative filtering: a linear residual graph convolutional network approach [C] // *Proceedings of the 34th AAAI Conference on Artificial Intelligence*, 2020: 27-34.
- [41] Liu ZW, Meng L, Jiang F, et al. Deoscillated graph collaborative filtering [Z/OL]. *arXiv Preprint*, arXiv: 2011.02100, 2020.
- [42] Cai XH, Huang C, Xia LH, et al. LightGCL: simple yet effective graph contrastive learning for recommendation [C] // *Proceedings of the 11th International Conference on Learning Representations*, 2023.
- [43] Ye HB, Li XJ, Yao Y, et al. Towards robust neural graph collaborative filtering via structure denoising and embedding perturbation [J]. *ACM Transactions on Information Systems*, 2023, 41(3): 59.
- [44] Sun JN, Zhang YX, Guo W, et al. Neighbor interaction aware graph convolution networks for recommendation [C] // *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2020: 1289-1298.
- [45] Wang X, Wang RJ, Shi C, et al. Multi-component graph convolutional collaborative filtering [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020: 6267-6274.
- [46] Wang X, Jin HY, Zhang A, et al. Disentangled graph collaborative filtering [C] // *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2020: 1001-1010.
- [47] Wu JC, He XN, Wang X, et al. Graph convolution machine for context-aware recommender system [J]. *Frontiers of Computer Science*, 2022, 16(6): 166614.
- [48] Ding CX, Zhao ZY, Li C, et al. Session-based recommendation with hypergraph convolutional networks and sequential information embeddings [J]. *Expert Systems With Applications*, 2023, 223: 119875.