

# 融合多视图对比学习和知识图谱的推荐算法<sup>①</sup>

王 光, 姜 皓

(辽宁工程技术大学 软件学院, 葫芦岛 125105)

通信作者: 姜 皓, E-mail: [1826011749@qq.com](mailto:1826011749@qq.com)



**摘 要:** 当前多数图对比学习驱动的推荐系统模型倾向于依赖单一视图进行训练, 这种做法不可避免地限制了模型对复杂数据特征的全面捕捉能力. 为此, 提出一种融合多视图对比学习和知识图谱的推荐算法 MKCLR (multi-view knowledge contrastive learning recommendation). 首先, 使用了 3 种视图增强方法, 分别是随机边丢弃, 添加均匀噪声扰动和随机游走算法, 为知识图谱和用户-物品图构建 3 个对比视图; 其次, 通过 LightGCN 进行编码, 并为之构建多组对比学习任务, 来最大化地提取和利用多视图数据中的丰富信息; 最后, 将主推荐任务与对比学习结合起来进行联合训练, 在 MIND, Last-FM 和 Alibaba-iFashion 这 3 个基准数据集上进行实验, 结果表明, MKCLR 在 Recall 和 NDCG 这两个评价指标上分别平均提升 5.78% 和 8.68%, 证明了所提方法的有效性.

**关键词:** 图神经网络; 多视图增强; 对比学习; 知识图谱; 推荐算法

引用格式: 王光, 姜皓. 融合多视图对比学习和知识图谱的推荐算法. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9853.html>

## Recommendation Algorithm Incorporating Multi-view Contrastive Learning and Knowledge Graph

WANG Guang, JIANG Hao

(Software College, Liaoning Technical University, Huludao 125105, China)

**Abstract:** Most of the current graph contrast learning-driven recommender models tend to rely on a single view for training, which inevitably limits the ability of the models to fully capture the features of complex data. To this end, a recommendation algorithm multi-view knowledge contrastive learning recommendation (MKCLR) integrating multi-view contrastive learning and knowledge graph is proposed in this study. First, three view enhancement methods, namely, random edge discarding, adding uniform noise perturbation, and random walk algorithm, are used to construct three contrasting views for the knowledge graph and user-item graph. Second, LightGCN is used to encode the knowledge graph and construct multiple contrastive learning tasks, aiming to maximize the extraction and utilization of the rich information in the multi-view data. Finally, the main recommendation task is combined with contrastive learning for joint training. Experiments conducted on MIND, Last-FM, and Alibaba-iFashion show an average increase of 5.78% and 8.68% of MKCLR in terms of Recall and NDCG indexes, respectively, validating the effectiveness of the proposed method.

**Key words:** graph neural network (GNN); multi-view enhancement; contrastive learning; knowledge graph (KG); recommendation algorithm

随着信息量的急剧膨胀, 推荐系统已经成为用户探索感兴趣内容的重要工具<sup>[1]</sup>. 传统的协同过滤推荐方

法核心理念在于: 用户间若存在相似的行为模式, 则他们在各类项目<sup>[2]</sup>上的偏好亦可能趋同. 协同过滤方法

<sup>①</sup> 基金项目: 国家自然科学基金 (62173171)

收稿时间: 2024-10-28; 修改时间: 2024-11-29; 采用时间: 2024-12-11; csa 在线出版时间: 2025-03-24

已在广泛领域内验证了其高效性,显著推动了推荐系统技术的发展。

近年来,协同过滤技术借助神经网络的深度融合以及对用户与项目潜在特性的捕捉,实现了显著优化,这一变革对传统矩阵分解策略<sup>[3]</sup>构成了有力挑战。同时,创新模型如融合变分自编码器、注意力机制及图神经网络的方法<sup>[4]</sup>,更是极大提升了协同过滤的性能。然而,它们面临着冷启动问题,用户与项目间交互数据的稀疏性成为制约性能提升的关键因素。为应对此挑战,研究者们开始将目光投向知识图谱,将其包含的丰富实体和关系融入推荐系统中,催生了知识图谱增强的推荐策略,旨在克服数据稀疏的局限性<sup>[5]</sup>。

知识图谱已被证明可以有效提升推荐系统效能,但其伴随的噪声与稀疏性挑战亦不容忽视,这些问题会制约性能的优化<sup>[6]</sup>。为应对这一困境,当前研究前沿正积极探索对比学习策略,对比学习已被当作有用的辅助信息来提高推荐系统的质量,因为它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问题的需求完全一致,以期在知识感知的推荐过程中实现更精细化的处理。

图对比学习框架包含两大核心组件:数据增强与对比学习。前者旨在生成节点的多个视图,后者则聚焦于探索这些视图间的一致性。当前研究主要聚焦于数据增强策略,例如 Yang 等人<sup>[7]</sup>提出 KGCL 模型,该模型基于图结构的增强方法,通过应用多样化的随机图变换技术生成了两个在结构特征或语义属性上相匹配的增强图,并在这两者之间实施了对比学习策略。Yu 等人<sup>[8]</sup>提出 SimGCL 模型,摒弃了图变换技术,转而在嵌入空间引入均匀分布的噪声来构建对比视图。此策略能够灵活地调控学习表示中所期望保留或舍弃的信息内容。Lin 等人<sup>[9]</sup>提出以往数据增强技术的局限性在于,随机移除边可能忽视了用户与物品间的邻近关系,未能充分释放对比学习的潜力。为克服这一局限,文中引入了 NCL 模型,该模型从结构性邻居和语义邻居出发对数据增强模块进行优化,从而在推荐系统中取得了显著成效。上述几种模型均擅长挖掘图结构数据中的内在联系,并借助对比学习机制增强了模型的泛化性能与鲁棒性。它们在应对数据稀疏性及冷启动挑战方面展现出优势,显著提升了推荐的精确度和个性化水平。尽管如此,这些模型亦面临若干局限,诸如易受数据噪声干扰,可能引发过拟合风险以及使用的

视图增强策略往往比较单一,忽视了单一视图增强策略带来的局限性。

为了解决这个问题,本文提出了一种融合多视图对比学习和知识图谱的推荐算法,该算法采用 3 种视图增强方法。一种是随机边丢弃,它通过对图结构进行细微的扰动,旨在削弱高度连接节点,即那些具有大量邻居的节点的过度影响力,从而平衡图数据的整体结构特性;第 2 种方法在学习到的节点嵌入上施加均匀分布的随机噪声,旨在平滑嵌入空间中的分布,促进模型学习到更加泛化和鲁棒的特征表示;第 3 种是采用随机游走算法,通过模拟节点之间的随机游走过程来增强和重新采样图结构,从而生成新的图视图。然后,为增强后的知识图谱和用户-物品图的 3 个视图分别构建了 3 组对比学习任务,最后,根据学习到的节点嵌入预测推荐列表。本文的核心贡献概述如下。

(1) 融合多视图增强机制进行图对比学习,提高模型的泛化能力,引入 3 种不同的视图增强方法构建视图,以避免单个增强方法造成的负面影响,更好地学习节点嵌入,改善推荐效果。

(2) 结合图对比学习与知识图谱,本文设计并实现了 MKCLR 模型,该框架将对对比学习与知识图谱联合应用到推荐算法中,通过对知识图谱和用户-物品增强图进行对比学习来获得更好的用户和物品嵌入,旨在通过这一综合策略增强推荐系统的稳健性,有效解决数据噪声与稀疏性带来的问题。

(3) 在 3 个广泛使用的公开数据集上,进行了全面而深入的实验评估。实验结果显示, MKCLR 模型在不同场景下均展现出优于现有推荐方法的性能。

## 1 相关工作

### 1.1 知识感知的推荐系统

在优化推荐系统时,知识图谱的融入成为一个重要的研究方向。现有的技术路径主要分为 3 种,分别是基于嵌入的方法,基于路径的方法和基于图神经网络的方法<sup>[10]</sup>。基于嵌入的方法<sup>[11,12]</sup>,其核心在于利用知识图谱中的丰富关系和实体,来增强推荐系统中的语义表示。比如,CKE 模型<sup>[11]</sup>巧妙地融合了多种辅助信息于协同过滤框架内,其中物品的结构性知识通过 TransR<sup>[13]</sup>进行编码。另一种具有代表性的方法是 DKN<sup>[12]</sup>,它集成了新闻的语义表示来学习更好的物品嵌入。

基于路径的方法<sup>[14,15]</sup>旨在通过构建元路径来实现

信息传播,挖掘知识图谱中物品间潜在的关联信息.例如, KPRN<sup>[16]</sup>采用长短期记忆网络对提取的元路径进行建模,并通过全连接层沿每条路径聚合用户偏好.此类方法相较于基于嵌入的方法,在捕获高阶知识感知的依赖关系方面展现出了一定优势.然而,基于路径的方法高度依赖于元路径的设计,这不仅需要深厚的领域知识,还耗费大量人力.此外,沿多元路径的信息整合过程也颇为耗时,影响了推荐系统的整体效率.

基于 GNN 的方法<sup>[17-19]</sup>将神经网络扩展到知识图谱的建模中,并使用学习到的特征进行推荐. KGAT<sup>[20]</sup>项目提出了一个新颖的图注意力机制,能够在知识图谱上有效传播用户和物品的嵌入信息,并通过多层感知机得到推荐评分.基于 GNN 的知识感知推荐系统研究致力于融合不同范式的优点, GNN 以其强大的高阶信息捕捉能力,在提取知识图谱中的深层语义方面表现出色. KGCN<sup>[21]</sup>通过限定邻居数量的采样策略,限制了知识图谱上的信息聚合范围; KGIN<sup>[22]</sup>更进一步,考虑了用户对知识图谱中不同关系的潜在兴趣,将关系嵌入融入聚合层,显著提升了推荐性能.

### 1.2 对比学习

近年来,对比学习作为一种自监督学习策略,在多个领域如自然语言处理<sup>[23]</sup>和图像识别<sup>[24]</sup>中展现了其独特的优势,成为当前研究的热点.其核心理念在于通过

对比不同视角下的正负样本来学习更加区分性的特征表示.鉴于其在这些领域的成功应用,研究人员开始探索将对比学习引入推荐系统<sup>[25]</sup>,以进一步提升推荐性能.

具体而言, SGL 模型<sup>[26]</sup>通过实施多种图结构扰动策略来丰富数据视角,从而增强模型的泛化能力.另一方面, CML 模型<sup>[27]</sup>则另辟蹊径,它聚焦于用户与物品之间的多样化行为关系,并借助对比学习来捕捉这些关系中的潜在模式,进而优化推荐效果. DHCN 模型<sup>[28]</sup>则通过构建 Transformed 超图与线图这一对互补视图,将模型处理流程分为两个并行通道.该模型融合了两个通道得到的会话嵌入,并引入对比学习进行预测,这一策略不仅丰富了数据表示,还增强了模型的泛化能力. KGCL 模型<sup>[7]</sup>利用知识图谱增强过程中产生的额外监督信号,指导跨视图对比学习框架的构建.

受这些先驱工作的启发,本文提出了一种新颖的融合多视图对比学习和知识图谱的推荐算法框架.该框架的核心在于巧妙地融合知识图谱的深度表示与用户-物品交互的增强策略,旨在通过多视图对比学习,从丰富的数据中提取出更加精准和鲁棒的推荐信号.

## 2 推荐算法框架 MKCLR

本文所提出的推荐算法框架 MKCLR 具体结构如图 1 所示.

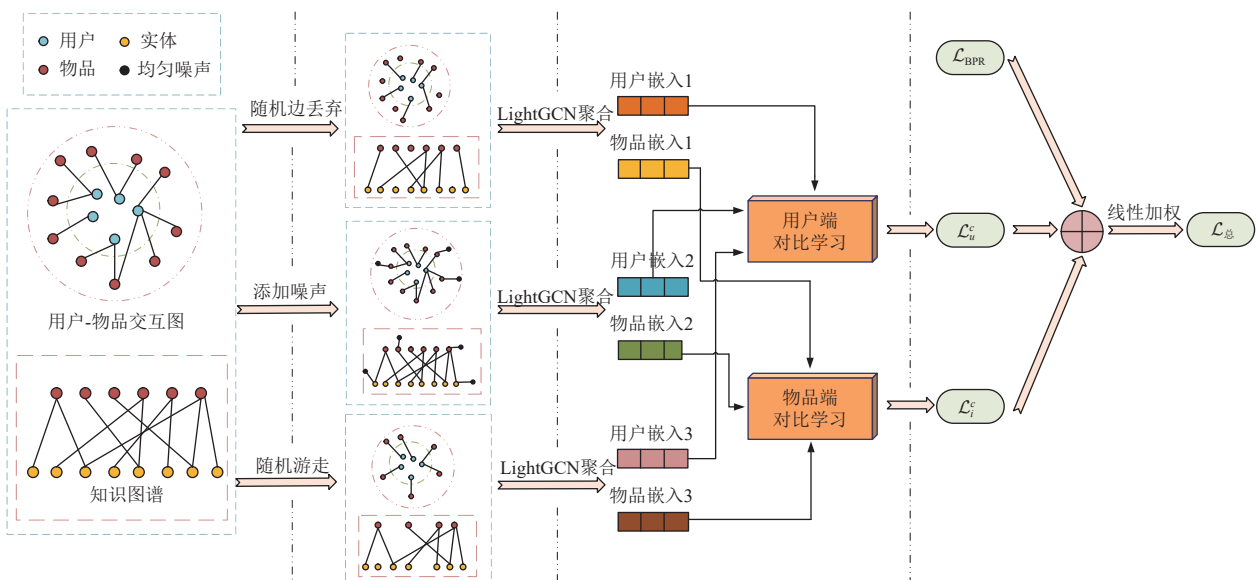


图 1 模型 MKCLR 的整体框架

主要包含 3 个模块:

(1) 多视图增强机制: 为全面保留并高效利用图结

构的固有信息,本文采取了 3 种增强策略,分别是随机边删除获得增强视图,添加均匀噪声构建扰动增强视

图和通过随机游走来构建增强视图。

(2) 构建多组对比学习任务: 分别为交互图和知识图谱执行图增强操作, 并使用图卷积网络进行特征编码得到用户嵌入和物品嵌入, 并两两分组构建用户端对比学习以及物品端对比学习, 以充分挖掘并利用其增强特性, 进一步提升模型对图结构深层特征的捕捉能力. 最终得到用户对比损失和物品对比损失.

(3) 模型预测与推荐: 在优化推荐系统性能的过程中, 本文引入了多任务学习框架, 其核心策略在于设定推荐任务为主任务, 并以对比学习任务作为辅助. 这一架构旨在通过联合优化整体的损失函数, 来增强模型的泛化能力, 进而促使推荐效果达到更优的层次.

## 2.1 轻量级的图卷积结构

本文借鉴了 LightGCN<sup>[29]</sup>的高效传播机制, 该机制摒弃了传统图卷积中复杂的特征变换与非线性激活步骤, 直接基于用户-项目二部图结构, 通过精简的方式聚合相邻节点的表征来迭代更新节点嵌入, 实现模型轻量化同时提升推荐性能. 因此, 本文采用 LightGCN 的信息传递策略, 以更有效地编码用户与物品间的交互行为. 编码过程如下所示:

$$x_u^{(l)} = \sum_{i \in N_u} \frac{x_i^{(l-1)}}{\sqrt{|N_u| |N_i|}} \quad (1)$$

$$x_i^{(l)} = \sum_{u \in N_i} \frac{x_u^{(l-1)}}{\sqrt{|N_i| |N_u|}} \quad (2)$$

$$x_u = \sum_{l=0}^L x_u^{(l)} \quad (3)$$

$$x_i = \sum_{l=0}^L x_i^{(l)} \quad (4)$$

其中,  $x_u^{(l)}$  和  $x_i^{(l)}$  分别表示第  $l$  层传播后的用户和物品嵌入表示, 对每一层的嵌入进行叠加可以得到最终的用户和物品嵌入  $x_u$  和  $x_i$ ,  $N_u$  和  $N_i$  分别表示用户  $u$  交互过的物品集合以及物品  $i$  所连接的用户集合.  $\sqrt{|N_u| |N_i|}$  是对称归一化项, 作用是防止嵌入向量的规模逐渐增大, 确保嵌入的尺度保持稳定. 在图结构的协同过滤框架内, 利用多层图传播机制的堆叠, 能够有效捕捉并分析高阶协同信号, 进而深化对用户与项目间复杂关系的理解.

## 2.2 随机边删除

随机边删除通过对图结构进行扰动, 生成多个子

图视图, 这些视图在保留原图大部分信息的同时, 也引入了一定的噪声和不确定性. 模型在训练过程中需要适应这种不确定性, 从而提高了对噪声和异常数据的鲁棒性. 这使得模型在实际应用中能够更好地处理不完整或带有噪声的数据, 能够更好地挖掘长尾物品与用户之间的潜在关系, 从而提高长尾物品的推荐性能.

文献[7]证明了通过对知识图谱中进行随机边删除可以筛选出那些在面临结构变动时保持稳健性, 且对噪声实体连接容忍度更高的物品. 这些物品不仅便于识别, 还能有效捕捉并反映与之相关联的用户偏好. 增强过程如式 (5) 所示:

$$\eta_1(\mathcal{G}_k) = ((e, r, i) \odot M_k) \quad (5)$$

其中,  $(e, r, i) \in \mathcal{G}_k$  是包含物品和相连接的实体以及关系的三元组,  $M_k$  是以概率生成随机的  $0, 1$  矩阵, 通过这种方式可以获取知识图谱的增强视图  $\eta_1(\mathcal{G}_k)$ .

同样的, 本文采用随机删除用户和物品之间交互的方式, 根据设定的概率  $p$ , 基于伯努利分布生成一个掩蔽向量  $M_u \in \{0, 1\}$ , 根据  $M_u$  对用户物品交互图  $\mathcal{G}_u$  进行掩码操作, 得到交互图的一个视图  $\sigma_1(\mathcal{G}_u)$ , 增强过程如式 (6) 所示:

$$\sigma_1(\mathcal{G}_u) = (M_u \odot \mathcal{G}_u) \quad (6)$$

对生成的两个视图  $\eta_1(\mathcal{G}_k)$  和  $\sigma_1(\mathcal{G}_u)$  进行图卷积操作得到第 1 组用户嵌入  $x_u^{(1)}$  和物品嵌入  $x_i^{(1)}$ .

## 2.3 添加均匀噪声

在深度学习的推荐系统领域内, 提升推荐效果的关键在于学习更为精准且高质量的嵌入表示. 现有研究警示, 随机丢弃图结构中的节点或边作为视图增强手段, 可能无意中削弱图的关键结构信息<sup>[8]</sup>. 文献[30]深入剖析并实证了嵌入间的对齐性与分布的均匀性对模型效能的显著影响: 对齐性强调相关嵌入在高维空间中的紧密邻近, 而均匀性则要求不同嵌入在整体空间中的分布保持均衡. 鉴于此, 优化嵌入表征的均匀性分布成为提升模型性能的有效途径.

添加均匀噪声是一种基于特征的视图增强方法, 其通过向原始表示中随机引入均匀分布的噪声来实现数据在表示层的增强. 这种方法旨在促进嵌入空间的正则化, 使其呈现更为均匀的分布特性, 并允许通过调整噪声强度来灵活控制表示的平滑性和一致性. 此策略不仅有效避免了因增强导致的语义扭曲, 还确保了原始特征中蕴含的有价值信息得以保留, 从而促进了



模型性能的进一步优化.

在获取知识图谱和交互图的两个子视图 $\eta_2(\mathcal{G}_k)$ 和 $\sigma_2(\mathcal{G}_u)$ 后,在执行式(1)、式(2)时加入扰动,如式(7)、式(8)所示:

$$x_u^{(l)*} = x_u^{(l)} + \Delta_u^{(l)} \quad (7)$$

$$x_i^{(l)*} = x_i^{(l)} + \Delta_i^{(l)} \quad (8)$$

其中, $x_u^{(l)*}$ 和 $x_i^{(l)*}$ 分别是添加了均匀噪声后的用户嵌入和物品嵌入, $\Delta_u^{(l)}$ 和 $\Delta_i^{(l)}$ 是添加到第 $l$ 层的噪声扰动,加入的噪声与原嵌入有着相同的维度,其约束条件是 $\|\Delta\|_2 = \varepsilon$ , $\varepsilon$ 作为超参数控制着噪声的大小.最终得到第2组用户嵌入 $x_u^{(2)}$ 和物品嵌入 $x_i^{(2)}$ .

#### 2.4 随机游走

随机游走不仅能够关注到节点的局部邻居信息,还能通过多次游走捕捉到图的全局结构信息<sup>[26]</sup>.这种全局和局部信息的结合使得模型能够更全面地理解节点之间的关系,从而更准确地预测节点之间的连接或推荐相关的物品.

随机游走的状态转移如式(9)所示:

$$X_{t+1} \sim \text{Uniform}(N(X_t)) \quad (9)$$

其中, $N(X_t)$ 表示当前节点 $X_t$ 的邻居节点集合, $\text{Uniform}(\cdot)$ 表示从当前节点的邻居节点中随机选择下一个节点.随机游走的长度 $L$ 如式(10)所示:

$$L = \sum_{t=0}^T I(X_{t+1} \in N(X_t)) \quad (10)$$

其中, $T$ 是每个节点进行随机游走的次数, $I$ 是指示函数,当 $X_{t+1}$ 是有效的邻居节点时返回1,否则返回0.如果当前节点没有邻居节点,或者达到预定的单次游走的长度 $L$ ,则终止游走.通过控制游走步长和次数等参数,灵活地调整生成子视图的大小和复杂度.这有助于在保持模型性能的同时,优化计算效率,降低模型的训练时间和资源消耗.

通过对知识图谱和交互图执行随机游走算法可以得到两个增强视图 $\eta_3(\mathcal{G}_k)$ 和 $\sigma_3(\mathcal{G}_u)$ ,对视图进行GCN操作后可以得到第3组用户嵌入 $x_u^{(3)}$ 和物品嵌入 $x_i^{(3)}$ ,经过实验验证,在超参数 $T$ 和 $L$ 均为2时,所获得的子图表现最优.

#### 2.5 多视图对比学习

为了综合利用图结构信息,增强模型对不同数据

集的泛化能力,本文结合上述3种视图增强方法分别对用户物品交互图和知识图谱进行图增强,使用式(1)、式(2)来编码特征,通过多层的训练来并捕捉数据中的高阶特征表示.本文对得到的用户嵌入和物品嵌入进行分组,以物品嵌入为例,即构建 $(x_i^{(1)}, x_i^{(2)})$ , $(x_i^{(1)}, x_i^{(3)})$ 和 $(x_i^{(2)}, x_i^{(3)})$ 这3组嵌入分别进行对比学习.为每个节点建立增强视图后,将同一节点不同视图作为正样本对,也就是 $(z'_u, z''_u)$ ,然后将不同节点的视图作为负样本对,也就是 $(z'_u, z'_v)$ .正样本对的辅助监督信号促进同一节点不同视图的一致性,负样本对的监督信号强化不同节点视图的差异性.很自然的,采用了InfoNCE损失函数来达到上述目的,如式(11)所示:

$$\mathcal{L} = \sum_{u \in U} -\log \frac{\exp(S(z'_u, z''_u)/\tau)}{\sum_{u \in U} \exp(S(z'_u, z'_v)/\tau)} \quad (11)$$

其中, $S(\cdot)$ 用于计算两个向量的相似度,这里采用了余弦相似度, $\tau$ 表示温度系数.通过最小化损失函数 $\mathcal{L}$ 来优化嵌入空间,目的是最小化正样本对之间的距离并且最大化负样本对之间的距离.通过综合三组对比学习任务得到的损失,通过不同的权重 $W_i$ 进行累加,最终得到物品对比损失,如式(12)所示:

$$\mathcal{L}_i^c = \sum_{i \in (i', i'', i''')} W_i \mathcal{L}_i \quad (12)$$

同样得,对用户嵌入执行对比学习后得到用户对比损失,如式(13)所示:

$$\mathcal{L}_u^c = \sum_{u \in (u', u'', u''')} W_u \mathcal{L}_u \quad (13)$$

综上所述,为了强化视图间的对比学习效果,本文将 $\mathcal{L}_i^c$ 和 $\mathcal{L}_u^c$ 相结合得到最终的对比学习目标损失函数 $\mathcal{L}_c$ ,如式(14)所示:

$$\mathcal{L}_c = \mathcal{L}_i^c + \mathcal{L}_u^c \quad (14)$$

#### 2.6 模型预测

为了提升模型性能和提高训练效率,本文采用联合训练实现多任务学习,使用经典贝叶斯个性化排名BPR损失函数来训练主推荐任务,并与对比学习一起进行梯度下降.定义的BPR损失函数如式(15)所示:

$$\mathcal{L}_b = \sum_{u \in U} \sum_{i \in N_u} \sum_{i' \notin N_u} -\log \sigma(f(u, i) - f(u, i')) \quad (15)$$

其中, $N_u$ 代表用户 $u$ 的交互记录, $i'$ 是从用户 $u$ 的非交

互项中抽取出的负实例,  $\sigma$ 表示激活函数,  $f(u, i)$ 表示用户  $u$  对物品  $i$  的偏好得分.

通过优化  $\mathcal{L}_b$  可以更精准地刻画用户与物品间的复杂交互关系. 在此基础上, 为了深入挖掘图结构的深层次信息及节点间的内在联系, 本文将图对比学习损失函数  $\mathcal{L}_c$  与  $\mathcal{L}_b$  相结合, 构建了一个综合性的总损失函数, 如式 (16) 所示:

$$\mathcal{L} = \mathcal{L}_b + \lambda_1 \mathcal{L}_c + \lambda_2 \|\theta\|_2^2 \quad (16)$$

其中,  $\lambda_1$  表示对比学习损失的权重,  $\lambda_2$  表示联合损失函数的正则化参数,  $\theta$  表示可学习的模型参数.

### 3 实验

#### 3.1 数据集与参数设置

为了确保评估的多样性和准确性, 本文使用了 3 个反映现实生活场景的不同的数据集: MIND 用于新闻推荐, Last-FM 用于音乐推荐, Alibaba-iFashion 用于购物推荐. 数据集可以在 <https://github.com/Hotawa/datasets> 处获得. 表 1 显示了本文实验数据集的统计信息, 这些数据集具有不同的交互稀疏度.

表 1 数据集信息

统计项	MIND	Last-FM	Alibaba-iFashion
Users	300000	23566	114737
Items	48957	48123	30040
Interactions	2545327	3034796	1781093
Entities	106500	58266	59156
Relations	90	9	51
KG Triplets	746270	464567	279155

本文的 MKCLR 模型是基于 PyTorch 实现的. 为确保实验的一致性与可比性, 所有嵌入向量的维度均固定为 64, 并设置学习率为 0.001, epoch 为 100, 以及批量大小为 1024 来优化模型性能. 模型优化过程中, 选用 Adam 优化器, 并采用 Xavier 进行参数初始化.

#### 3.2 评价方案

为了确保评估的公平性, 本文将数据集分为 3 个部分: 70% 用于训练, 10% 用于超参数调整, 20% 用于测试. 对于性能评估, 使用两个代表性指标: 召回率  $Recall@20$  和归一化折损累计增益  $NDCG@20$  来评估最佳推荐项目的准确性<sup>[20,31]</sup>.

(1) 召回率: 作为一项关键性能指标, 它侧重于评估在所有用户真正偏好的物品中, 模型成功推荐给用户的那部分物品所占的比例. 这一指标直观地反映了

推荐系统对用户兴趣的覆盖广度. 如式 (17) 所示:

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

其中,  $TP$  代表被正确推荐且用户实际喜欢的项目数量, 即真阳性; 而  $FN$  则是指用户实际喜欢但系统未推荐的项目, 构成假阴性. 这些指标直接反映了推荐系统的交互推荐结果, 其中真阳性是推荐准确性的直接体现, 而假阴性则揭示了系统可能遗漏的潜在兴趣点. 通过精确计算这些指标, 能够更全面地评估推荐系统的效能与准确性.

(2) 归一化折损累计增益:  $NDCG$  作为  $DCG$  (折损累积增益) 的改进版本, 有效解决了因用户间推荐列表长度差异导致的直接比较不准确问题. 它通过归一化处理, 确保了不同用户间的性能评估具有一致性和可比性.  $NDCG$  不仅评估了推荐项目的准确性, 还强调了推荐顺序的重要性, 即项目在用户列表中更靠前的位置应更能体现用户的真实偏好, 从而精确反映预测结果的精准排序能力. 其计算公式如式 (18) 所示:

$$NDCG = \sum_{u \in U_{test}} \frac{1}{Y_u} \sum_{i=1}^k \frac{2^{t_i} - 1}{lb(i+1)} \quad (18)$$

其中,  $U_{test}$  表示测试用户集,  $Y_u$  表示用户  $u$  的最大  $NDCG$  值;  $t_i=1$  表示击中,  $t_i=0$  表示未击中.

#### 3.3 基线模型

为了评估模型的性能, 本文将其与以下几个基线模型进行比较.

##### (1) 传统的协同过滤方法

**BPR**: 一种基于隐式反馈的成对排序损失的矩阵分解方法, 通过优化用户对物品的偏好排序来提高推荐质量.

**GC-MC**: 一种将推荐视为用户-物品图上的链接预测问题的算法, 并为此提出了一种基于图自动编码器的矩阵填充框架.

**LightGCN**: 该方法去除了传统 GCN 模型中的激活函数和特征转换步骤, 仅保留了最基本的邻域聚合操作. 这一简化不仅减少了模型的复杂度, 还提高了推荐性能.

##### (2) 自监督学习推荐系统

**SGL**: 一种引入自监督学习范式的 GNN 推荐方法. 该方法通过在用户-物品图上应用随机增强技术, 生成多个视图, 并利用这些视图进行自监督学习.

(3) 基于嵌入的知识感知推荐

**CKE**: 一种基于嵌入的知识图谱推荐系统, 它利用 **TransR** 来丰富物品表示, 通过对结构知识的训练来增强协同过滤的效果.

(4) 基于 GNN 的知识图增强推荐

**KGCN**: 一种结合了知识图谱和图神经网络的推荐系统方法. 它旨在通过利用知识图谱中的高阶信息来丰富物品表示, 并结合用户嵌入的偏好作为权重, 从而增强协同过滤的效果.

**KGAT**: 计算注意力分数来反映知识三元组的重要性, 并基于这些分数来更新用户和物品的嵌入表示. 通过结合协同过滤和知识图谱的注意力机制, 来提高推荐系统的性能.

**KGIN**: 特别关注于建模用户对关系中的意图, 并通过关系路径感知的聚合方式来有效地捕获知识图谱中的丰富信息.

(5) 自监督知识感知推荐系统

**KGCL**: 是一种结合了自监督学习和知识图谱的推荐系统方法, 它引入了图对比学习来减少知识图谱中的潜在噪声, 并进一步提升推荐性能.

3.4 结果分析

表 2 中展示了实验结果, 其中最优结果进行了加粗标注.

表 2 3 种数据集上的性能对比 (%)

Model	MIND		Last-FM		Alibaba-iFashion	
	Recall	NDCG	Recall	NDCG	Recall	NDCG
BPR	9.38	4.69	6.9	5.85	8.22	5.01
GC-MC	9.84	4.91	7.09	6.31	8.45	5.02
LightGCN	10.33	5.20	7.38	6.47	10.58	6.52
SGL	10.32	5.39	8.79	7.75	11.41	7.13
CKE	9.01	3.82	8.45	7.18	8.35	5.12
KGCN	8.87	4.31	8.79	6.94	9.83	6.33
KGAT	9.07	4.42	8.70	7.43	9.57	5.77
KGIN	10.44	5.27	9.00	7.79	11.44	7.23
KGCL	10.57	5.46	9.05	7.69	11.46	7.19
MKCLR	<b>10.80</b>	<b>5.68</b>	<b>9.53</b>	<b>8.74</b>	<b>12.59</b>	<b>7.94</b>
Improve	<b>2.18</b>	<b>4.03</b>	<b>5.30</b>	<b>12.2</b>	<b>9.86</b>	<b>9.82</b>

由表 2 可见, 本文所提出的 **MKCLR** 在两个指标 **Recall@20** 和 **NDCG@20**、3 个数据集上的表现均优于其他基线模型, 这归功于以下 3 个方面, 首先为了有效应对协同过滤推荐算法中的冷启动难题, 本文将知识图谱作为一种辅助信号来分析用户的历史行为, 从而提高推荐的准确性和多样性; 其次利用图对比学习的自监督特性来缓解推荐系统中的数据稀疏性问题,

通过这一方法, 系统能够在有限的交互数据下学习到更丰富的用户与物品特征, 从而增强了系统的鲁棒性; 最后为了提高在不同数据集下的泛化能力, 采用 3 种图增强方式融合图对比学习来学习用户和物品的嵌入表示, 以丰富嵌入的维度, 确保推荐系统的稳定性.


3.5 超参数敏感性分析

为了评估不同超参数取值对模型性能的影响, 本文对 3 个关键参数进行实验分析, 分别是对比学习损失权重  $\lambda$ , 温度超参数  $\tau$  和控制噪声大小的参数  $\epsilon$ .


(1) 对比学习损失权重  $\lambda$

$\lambda$  是对比损失在主损失函数中的权重, 其值越大, 对比学习对模型的影响就越大. 本文在 {0.05, 0.1, 0.2, 0.3, 0.4, 0.5} 的范围内变化, 研究其值变化对 Last-FM 和 Alibaba-iFashion 数据集实验结果的影响.

观察图 2 可知, Last-FM 数据集在  $\lambda$  值为 0.1 时模型性能最优, 随后性能随  $\lambda$  值增大而递减; 对于 Alibaba-iFashion,  $\lambda$  取 0.2 时各项指标达到峰值. 这表明, 不同数据集下参数  $\lambda$  的最优设定各不相同, 此现象合乎情理. 鉴于各数据集原始数据质量存在差异, 适当调整  $\lambda$  值能有效平衡增强视图对比学习任务与其他任务间的权重, 进而提升推荐系统的整体效能.



(a) Last-FM数据集



(b) Alibaba-iFashion数据集

图 2 参数  $\lambda$  的影响

(2) 温度超参数  $\tau$

在对比学习的框架中, 温度参数  $\tau$  扮演着至关重要的角色, 它精细调控模型对困难负样本的关注度. 随着  $\tau$  值的递增, 模型对负样本的敏感度逐渐减弱, 导致模

型学习没有轻重;反之,  $\tau$  值减小则增强了模型对负样本的重视, 导致模型过于严苛, 错误地将邻近的相似样本也视为异类, 损害了模型的语义区分能力. 为寻求  $\tau$  的最优配置, 本文在  $\{0.05, 0.1, 0.2, 0.3, 0.4, 0.5\}$  的范围内进行了详尽搜索, 图 3 直观展示了 Last-FM 和 Alibaba-iFashion 数据集下性能指标随  $\tau$  值变化的趋势.

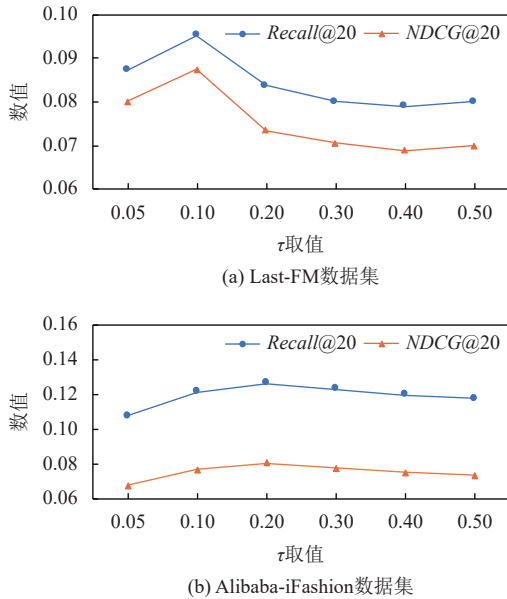


图 3 参数  $\tau$  的影响

由图 3 可以看出, 模型性能随着  $\tau$  值的增大呈现出先上升后下降的趋势. 在 Last-FM 数据集中, 当  $\tau$  设定为 0.1 时, 模型展现出最佳性能; 而在 Alibaba-iFashion 数据集中, 最优性能则出现在  $\tau$  值为 0.2 时. 这一现象表明, 参数  $\tau$  的最优取值因数据集而异, 这是合理的, 因为不同数据集的正负样本分布存在差异. 为优化模型性能, 需根据数据集的具体情况调整  $\tau$  值, 以确保特征分布的均衡性更为合理.

### (3) 嵌入噪声大小参数 $\epsilon$

本文模型引入了扰动增强视图机制, 该机制通过参数  $\epsilon$  来调节嵌入噪声的强度. 具体而言,  $\epsilon$  值越大, 所引入的噪声就越显著, 导致节点表示与原始状态之间的偏差增大, 可能削弱推荐系统的性能. 相反, 若  $\epsilon$  值过小, 则噪声扰动不足以对节点表示产生有效影响, 极端状况下, 扰动增强视图将趋同于原始图结构. 为了确定最佳的  $\epsilon$  值, 实验设计中, 本文从集合  $\{0.01, 0.05, 0.1, 0.2, 0.5\}$  中选取不同  $\epsilon$  值进行测试. 图 4 展示了不同数据集下, 各性能指标随  $\epsilon$  值变化的趋势.

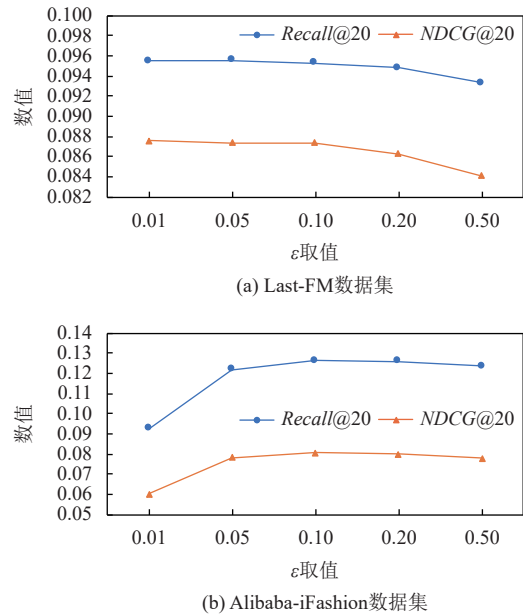


图 4 参数  $\epsilon$  的影响

观察图 4 可知, 过度增加扰动会导致模型性能衰退. 具体而言, 在 Last-FM 数据集上,  $\epsilon$  设为 0.05 时模型性能达到峰值; 而在 Alibaba-iFashion 数据集中, 最优性能则出现在  $\epsilon$  为 0.1 时. 这表明, 不同数据集上参数  $\epsilon$  的最优取值存在差异, 此现象是合理的. 鉴于各数据集的原始嵌入分布各具特点, 唯有施加适度的扰动, 才能促进特征分布的均匀化.

### 3.6 消融实验

为了验证 MKCLR 中关键部分多视图增强融合对比学习的有效性, 进行消融实验, 通过对比仅使用随机边丢弃, 添加均匀噪声嵌入和随机游走来分别得到 3 个变体 MKCLR/e, MKCLR/n 和 MKCLR/r, 将 3 个变体在上述 3 个数据集上进行实验, 结果如表 3 所示, 可以看出以下结论.

表 3 消融实验结果 (%)

Model	MIND		Last-FM		Alibaba-iFashion	
	Recall	NDCG	Recall	NDCG	Recall	NDCG
MKCLR/e	10.61	5.47	9.09	8.17	11.41	7.17
MKCLR/n	10.73	5.59	8.73	8.19	11.48	7.26
MKCLR/r	9.50	4.78	7.37	6.39	9.97	6.12
<b>MKCLR</b>	<b>10.80</b>	<b>5.68</b>	<b>9.53</b>	<b>8.74</b>	<b>12.59</b>	<b>7.94</b>

(1) 在 3 个不同领域的数据集下, 本文模型均优于其他的变体, 证明了通过对知识图谱和用户物品交互图进行多视图增强结合对比学习可以有效得提升模型性能.

(2) MKCLR/e, MKCLR/n 和 MKCLR/r 在不同数



据集上的优势差异,主要归因于不同数据集的内在结构特性与各自增强策略的匹配度不同. MKCLR 通过集成多种增强方法,提高了模型对不同类型数据集的适应能力,避免了单一方法的局限性,有效得提高了模型的泛化能力.

### 3.7 稀疏物品实验

为了验证 MKCLR 在稀疏项目推荐中的效果,本文对 Last-FM 测试集按物品交互密度进行升序排序,并取出前 50% 按交互密度从小到大分为 5 组,每组物品数量相等,对不同的物品组进行实验. 由图 5、图 6 的实验结果可知: MKCLR 在处理稀疏物品时对比其他的基线模型仍然具有更高的  $Recall@20$  和  $NDCG@20$  值,尤其是在为低交互密度物品进行推荐时,其性能领先更为优越,这归功于 MKCLR 将知识图谱融入了推荐系统中,并借助对比学习解决数据稀疏性问题,有效得缓解了冷启动问题. 实验数据揭示, MKCLR 在仅依赖有限的交互信息条件下,依然展现出卓越的能力来学习节点特征,同时维持了高效的预测性能,有力证明了其对于稀疏数据环境的适应性.




图 5  $Recall@20$  值变化




图 6  $NDCG@20$  值变化

## 4 总结

本文提出了一种融合多视图对比学习和知识图谱的推荐算法框架,该框架通过 3 种视图增强方法分别

是随机边丢弃,添加均匀噪声和随机游走来构建用户物品交互图视图和知识图谱视图,并借助图对比学习进行自监督学习,将对比损失与主推荐任务损失相结合以训练模型. 在 3 个不同领域的公开数据集上进行实验,结果表明, MKCLR 相比其他基线模型拥有更优越的推荐性能,也很好得缓解了数据稀疏问题. 在未来的工作中,将进一步探究更复杂的视图增强方法,以获取更优秀的性能.

### 参考文献

- 1 Sun F, Liu J, Wu J, *et al.* BERT4Rec: Sequential recommendation with bidirectional encoder representations from Transformer. Proceedings of the 28th ACM International Conference on Information and Knowledge Management. Beijing: ACM, 2019. 1441–1450. [doi: 10.1145/3357384.3357895]
- 2 He XN, Liao LZ, Zhang HW, *et al.* Neural collaborative filtering. Proceedings of the 26th International Conference on World Wide Web. Perth: ACM, 2017. 173–182. [doi: 10.1145/3038912.3052569]
- 3 He XN, Du XY, Wang X, *et al.* Outer product-based neural collaborative filtering. Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm: AAAI Press, 2018. 2227–2233.
- 4 Chen JY, Zhang HW, He XN, *et al.* Attentive collaborative filtering: Multimedia recommendation with item-and component-level attention. Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Tokyo: ACM, 2017. 335–344. [doi: 10.1145/3077136.3080797]
- 5 常亮, 张伟涛, 古天龙, 等. 知识图谱的推荐系统综述. 智能系统学报, 2019, 14(2): 207–216.
- 6 Tian Y, Yang YH, Ren XD, *et al.* Joint knowledge pruning and recurrent graph convolution for news recommendation. Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021. 51–60. [doi: 10.1145/3404835.3462912]
- 7 Yang YH, Huang C, Xia LH, *et al.* Knowledge graph contrastive learning for recommendation. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 1434–1443. [doi: 10.1145/3477495.3532009]
- 8 Yu JL, Yin HZ, Xia X, *et al.* Are graph augmentations necessary? Simple graph contrastive learning for

- recommendation. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 1294–1303. [doi: [10.1145/3477495.3531937](https://doi.org/10.1145/3477495.3531937)]
- 9 Lin ZH, Tian CX, Hou YP, *et al.* Improving graph collaborative filtering with neighborhood-enriched contrastive learning. Proceedings of the 2022 ACM Web Conference. Lyon: ACM, 2022. 2320–2329. [doi: [10.1145/3485447.3512104](https://doi.org/10.1145/3485447.3512104)]
- 10 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. 计算机学报, 2018, 41(7): 1619–1647. [doi: [10.11897/SP.J.1016.2018.01619](https://doi.org/10.11897/SP.J.1016.2018.01619)]
- 11 Zhang FZ, Yuan NJ, Lian DF, *et al.* Collaborative knowledge base embedding for recommender systems. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016. 353–362. [doi: [10.1145/2939672.2939673](https://doi.org/10.1145/2939672.2939673)]
- 12 Wang HW, Zhang FZ, Xie X, *et al.* DKN: Deep knowledge-aware network for news recommendation. Proceedings of the 2018 World Wide Web Conference. Lyon: ACM, 2018. 1835–1844. [doi: [10.1145/3178876.3186175](https://doi.org/10.1145/3178876.3186175)]
- 13 Lin YK, Liu ZY, Sun MS, *et al.* Learning entity and relation embeddings for knowledge graph completion. Proceedings of the 29th AAAI Conference on Artificial Intelligence. Austin: AAAI, 2015. 2181–2187.
- 14 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)]
- 15 Sun Z, Yang J, Zhang J, *et al.* Recurrent knowledge graph embedding for effective recommendation. Proceedings of the 12th ACM Conference on Recommender Systems. Vancouver: ACM, 2018. 297–305. [doi: [10.1145/3240323.3240361](https://doi.org/10.1145/3240323.3240361)]
- 16 Wang X, Wang DX, Xu CR, *et al.* Explainable reasoning over knowledge graphs for recommendation. Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019. 5329–5336. [doi: [10.1609/aaai.v33i01.33015329](https://doi.org/10.1609/aaai.v33i01.33015329)]
- 17 Scarselli F, Gori M, Tsoi AC, *et al.* The graph neural network model. IEEE Transactions on Neural Networks, 2009, 20(1): 61–80. [doi: [10.1109/TNN.2008.2005605](https://doi.org/10.1109/TNN.2008.2005605)]
- 18 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)]
- 19 钱忠胜, 赵畅, 俞情媛, 等. 结合注意力 CNN 与 GNN 的信息融合推荐方法. 软件学报, 2023, 34(5): 2317–2336. [doi: [10.13328/j.cnki.jos.006405](https://doi.org/10.13328/j.cnki.jos.006405)]
- 20 Wang X, He XN, Cao YX, *et al.* KGAT: Knowledge graph attention network for recommendation. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: ACM, 2019. 950–958. [doi: [10.1145/3292500.3330989](https://doi.org/10.1145/3292500.3330989)]
- 21 Wang HW, Zhao M, Xie X, *et al.* Knowledge graph convolutional networks for recommender systems. Proceedings of the 2019 World Wide Web Conference. San Francisco: ACM, 2019. 3307–3313. [doi: [10.1145/3308558.3313417](https://doi.org/10.1145/3308558.3313417)]
- 22 Wang X, Huang TL, Wang DX, *et al.* Learning intents behind interactions with knowledge graph for recommendation. Proceedings of the 2021 Web Conference. Ljubljana: ACM, 2021. 878–887. [doi: [10.1145/3442381.3450133](https://doi.org/10.1145/3442381.3450133)]
- 23 Fu H, Zhou SJ, Yang QH, *et al.* LRC-BERT: Latent-representation contrastive knowledge distillation for natural language understanding. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI, 2021. 12830–12838. [doi: [10.1609/aaai.v35i14.17518](https://doi.org/10.1609/aaai.v35i14.17518)]
- 24 Deng Y, Yang JL, Chen D, *et al.* Disentangled and controllable face image generation via 3D imitative-contrastive learning. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 5154–5163.
- 25 Wei YW, Wang X, Li Q, *et al.* Contrastive learning for cold-start recommendation. Proceedings of the 29th ACM International Conference on Multimedia. Chengdu: ACM, 2021. 5382–5390. [doi: [10.1145/3474085.3475665](https://doi.org/10.1145/3474085.3475665)]
- 26 Wu JC, Wang X, Feng FL, *et al.* Self-supervised graph learning for recommendation. Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021. 726–735. [doi: [10.1145/3404835.3462862](https://doi.org/10.1145/3404835.3462862)]
- 27 Wei W, Huang C, Xia LH, *et al.* Contrastive meta learning with behavior multiplicity for recommendation. Proceedings of the 15th ACM International Conference on Web Search and Data Mining. New York: ACM, 2022. 1120–1128. [doi: [10.1145/3488560.3498527](https://doi.org/10.1145/3488560.3498527)]

- 28 Xia X, Yin HZ, Yu JL, *et al.* Self-supervised hypergraph convolutional networks for session-based recommendation. Proceedings of the 35th AAAI Conference on Artificial Intelligence. AAAI, 2021. 4503–4511.
- 29 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)]
- 30 Wang CY, Yu YQ, Ma WZ, *et al.* Towards representation alignment and uniformity in collaborative filtering. Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Washington: ACM, 2022. 1816–1825. [doi: [10.1145/3534678.3539253](https://doi.org/10.1145/3534678.3539253)]
- 31 Xia LH, Xu Y, Huang C, *et al.* Graph meta network for multi-behavior recommendation. Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021. 757–766. [doi: [10.1145/3404835.3462972](https://doi.org/10.1145/3404835.3462972)]

(校对责编: 张重毅)