对比式多行为推荐的知识增强

Hongrui Xuan 南京航空航天大学 中国南京 1692595335@nuaa.edu.cn

Yi Liu 南京航空航天大学 中国南京 liuyi-sx21@nuaa.edu.cn

Bohan Li*南京航空航天大学 中国南京 bhli@nuaa.edu.cn

Hongzhi Yin 昆士兰大学 澳大利亚布里斯班 h.yin1@uq.edu.au

arXiv:2301.05403v2 [cs.IR] 3 Mar 2023

摘要

设计良好的推荐系统能够准确捕捉用户和物品的属性，反映个体的独特偏好。传统推荐技术通常侧重于对用户与物品之间单一类型的行为进行建模。然而，在许多实际推荐场景中（例如社交媒体、电子商务），用户-物品关系中存在多种类型的交互行为，例如在线购物平台上的点击、标记为收藏和购买。因此，如何充分利用多行为信息进行推荐，对现有系统至关重要，同时也带来了两个有待探索的挑战：（1）利用用户的个性化偏好捕捉多行为依赖关系；（2）解决因目标行为的稀疏监督信号而导致的推荐不足问题。本文提出一种知识增强多行为对比学习推荐（KMCLR）框架，其中包含两项对比学习任务和三个功能模块，分别用于应对上述挑战。具体而言，我们设计了多行为学习模块，以提取用户的个性化行为信息，增强用户嵌入；并在知识增强模块中利用知识图谱，为物品推导出更稳健的知识感知表征。此外，在优化阶段，我们对用户多种行为之间的粗粒度共性和细粒度差异进行建模，以进一步提升推荐效果。在三个真实世界数据集上开展的大量实验和消融测试表明，KMCLR 优于多种最先进的推荐方法，并验证了该方法的有效性。

CCS 概念

• **信息系统** →**推荐系统**;

关键词

多行为推荐；知识图谱；对比学习

ACM 引用格式：

Hongrui Xuan、Yi Liu、Bohan Li 和 Hongzhi Yin。2023。面向对比式多行为推荐的知识增强。载于第十六届 *ACM* 国际网络搜索与数据挖掘会议论文集（*WSDM '23*），*2023*年*2*月*27*日至*3*月*3*日，新加坡，新加坡。ACM，美国纽约州纽约，9页。https://doi.org/10.1145/3539597.3570386

*通讯作者

允许免费制作本作品全部或部分内容的数字或纸质副本，供个人或课堂使用，但不得为营利或商业利益而制作或分发副本，且副本必须包含本声明以及首页的完整引文。对于本作品中由 ACM 以外方所有的组成部分，必须尊重其版权。注明出处后可以摘录。若要以其他方式复制、重新出版、发布到服务器或分发至列表，须事先获得具体许可和/或支付费用。请通过 permissions@acm.org 联系我们申请许可。
WSDM '23，*2023*年*2*月*27*日至*3*月*3*日，新加坡，新加坡© 2023 计算机协会。
ACM ISBN 978-1-4503-9407-9/23/02...$15.00
https://doi.org/10.1145/3539597.3570386

1 引言

推荐系统旨在根据用户偏好，为用户提供个性化物品；它们已成为缓解各种在线应用中信息过载问题的关键组成部分 [6, 22, 26, 27]。如何从用户的行为中准确捕捉其偏好，是实现个性化推荐的关键。协同过滤（CF）技术是传统且有效的方法，它根据观测到的行为数据预测用户偏好。CF 范式的核心思想是将用户-物品交互分解为潜在表示，并基于向量化的用户/物品表征挖掘个体用户偏好的相似性，从而提供推荐 [8]。

随着深度学习的快速发展，神经网络已被用于增强协同过滤架构。例如，2017年，He 等人和 Xue 等人提出了多层感知机，并提出了 NCF [8] 和 DMF [34],，使协同过滤能够处理非线性交互。2018年，Du 等人通过堆叠多个自编码器网络 [18],，设计了一种将高维稀疏用户行为数据映射为低维稠密表征 [2]的方法。受图神经网络近期成功的启发，其他研究将用户-物品交互建模为图，以挖掘高阶用户-物品关系

这些模型执行消息传递和邻域

层级的、基于交互图的特征聚合，以生成节点级嵌入（例如，NGCF [24] 和图卷积网络 [37]）。

然而，大多数现有方法只考虑用户与物品之间存在单一类型的行为，因此无法从复杂的多重协作关系中提取有用信息，进而提供充分的推荐。实际上，在许多现实场景中，推荐系统需要处理更复杂的用户-物品多重交互

以全面反映用户多维度的偏好。例如，用户可以在电子商务平台上通过不同方式与物品交互（如点击、标记为收藏和购买）。这些行为从不同的意图维度刻画了用户偏好，可作为辅助知识来增强信息，并帮助完成目标行为的推荐任务。那么，如何准确捕捉行为多样性之间的依赖关系，并区分用户之间的差异，是一项富有挑战但很有价值的工作。为应对这一挑战，许多现有研究探索了多行为推荐。例如，ATRANK [38] 关注序列推荐中不同用户行为之间的特征交互，并重视用户历史行为的单序列视图。MATN [30] 利用自注意力机制对不同类型行为之间的成对相关性进行编码，从而推荐目标行为。

尽管上述方法确实有效，但实际研究中仍存在两项局限：（1）目标行为数据稀疏：大多数推荐系统利用监督信息进行训练，因此，充足的目标行为数据对于预测结果的准确性至关重要。遗憾的是，在现实场景中，与其他类型的交互相比，目标行为下观察到的交互往往较为稀疏。显而易见，在电子商务平台上，用户购买行为的数据量远低于点击数据；若直接整合某些类型的行为，就会牺牲推荐性能。（2）个体行为多样性：不同类型交互之间的依赖关系十分复杂，而多种行为类型之间的相互依赖关系因用户而异，因此带来了两个问题：一是如何建模不同类型行为之间粗粒度的共性，二是如何建模用户多行为之间细粒度的差异。在实际场景中，个体会根据自身习惯表现出不同的行为模式。例如，有些用户经常将商品标记为收藏，但只偶尔购买；另一些用户可能不习惯使用加入购物车功能。因此，如何构建高效的信息传递框架以提取充分的多行为模式至关重要。

最近，许多研究将对比学习（CL）引入推荐领域，并取得了一定成果 [29]。我们发现，对比学习非常适合用于建模多行为信息，以探索用户-物品关系之间的粗粒度共性和细粒度差异。同时，知识图谱（KG）已广泛应用于推荐领域，并成为一种热门的信息补全方法。因此，受对比学习和知识图谱相关工作的启发，我们提出了知识增强多行为对比学习推荐（KMCLR）框架，以解决上述局限。具体而言，KMCLR 由三个模块组成：多行为学习模块、知识增强模块和联合学习模块，用于从多个视角学习用户-物品表示。我们的多行为学习模块捕捉跨类型行为依赖关系，利用来自不同类型行为的额外监督信号来补充和增强用户级信息。知识增强模块则提出了一种关系感知的知识聚合机制，提取额外的知识图谱信息，以指导跨视图信号的数据扩展。

并实现物品级信息增强。最后，提出两种不同的对比学习任务和一种损失范式，以最大化用户表示之间的差异，同时最小化同一用户不同行为之间的差距。

总之，我们的工作贡献概括如下：

- 我们提出了一种用于推荐的新框架 KMCLR，通过结合多行为消息与知识图谱消息，增强用户级和物品级的信息，强调从不同视角对用户-物品信息进行建模，从而解决目标行为数据稀疏的问题。
- 在 KMCLR 框架中，我们提出了两种对比学习任务和一种损失范式，能够更好地建模行为之间的粗粒度共性以及用户之间的细粒度差异，从而提升推荐性能。据我们所知，这是首次将多行为对比学习和知识图谱对比学习联合引入推荐领域。
- 我们在三个真实世界数据集上开展了多种实验，结果表明，我们的框架优于各种最先进的推荐方法。此外，我们还进行了消融研究，以更好地理解 KMCLR 的模型设计，并验证关键组件的有效性。

2 预备知识

在我们研究的任务中，令 U 和 V 分别表示用户集和物品集：$U = \{u_1, \ldots\ldots, u_i, \ldots\ldots, u_I\}$ 和 $V = \{e_1, \ldots, e_j, \ldots, e_J\}$，其中 I 和 J 分别表示用户数和物品数。下面给出 KMCLR 中关键概念的详细定义：

用户-物品多行为交互图。用户-物品多行为交互图。用户-物品多行为交互图。由于用户-物品交互中存在多种行为类型，多行为交互图定义为：$G_u = (U, \Theta, V)$，其中 $\Theta = \{\theta^1, \ldots, \theta^k, \ldots, \theta^K\}$ 是表示 K 种行为类型的边的集合。具体而言，如果用户 u_i 和物品 v_j 在行为类型 k 下发生交互，则 $\theta^k_{i,j} = 1$，否则 $\theta^k_{i,j} = 0$。

物品-物品关系知识图谱。物品-物品关系知识图谱。物品-物品关系知识图谱。考虑到物品外部知识的丰富性，我们采用传统三元组方法定义知识图谱：$G_v = (H, R, T)$，其中 H 表示头实体集合，R 是关系集合，T 表示尾实体集合。其中，这三个集合中索引相同的元素组合构成一个三元组（h，r，t），它反映了头实体 h 与尾实体 t 之间的语义关系 r。具体而言，我们参照文献 [31] 中的形式来构建 G_v。

任务定义。任务定义。任务定义。基于上述定义，我们将所研究的任务形式化如下：

输入：输入：输入：用户-物品多行为交互图 $G_u = (U, \Theta, V)$ 和物品-物品关系知识图谱 $G_v = (H, R, T)$。

输出：输出：输出：一个预测函数，用于推断用户 u_i 与物品 v_j 在 k 类行为下的交互概率 $y^k_{i,j}$。

3 方法

KMCLR 模型的整体架构如图 1 所示。我们的模型主要由三个部分组成：多行为学习模块、知识增强模块和联合学习模块。我们提出了两类对比学习任务，以捕捉多行为交互特征和物品层知识特征。

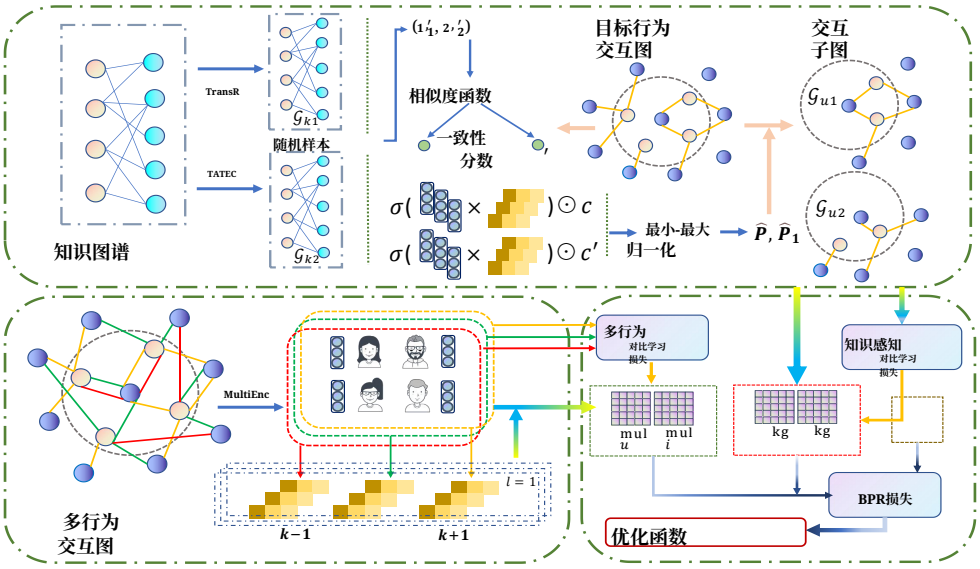

图1：KMCLR 框架的模型架构。

3.1 多行为学习模块

在该模块中，将用户的多行为交互图输入多行为编码器。我们通过该编码器构建用户的单行为表征。KMCLR 根据其他行为与目标行为之间的对比损失优化用户-物品嵌入。此过程利用多行为信息增强用户层面的嵌入表示。

3.1.1 多行为信息编码与聚合。 基于图的推荐通常在由所有行为构建的用户-物品图上进行，从而能够考虑全局多跳交互。为了充分利用多行为交互图，同时将高阶连通性注入多元关系，我们开发了一种行为上下文感知信息编码器，用于学习单一行为下的用户表示：

$$v_u^k, v_i^k = MultiEnc^k(G_u, u, k), \tag{1}$$

其中， v_u^k 和 v_i^k 表示在行为 k 下获得的用户 u 和物品 i 的表征。$MultiEnc^k$（~）是一个可选的多行为编码器。受 Light-GCN [7] 的轻量级架构和先进的信息传播框架 MB-GMN [32], 的启发，我们使用以下公式作为 $MultiEnc^k$（~），来计算节点（由用户和物品组成）的表征：

$$v_u^{k,(l+1)} = \sum_{i \in \mathcal{N}_u^k} v_i^{k,l}; \qquad v_i^{k,(l+1)} = \sum_{u \in \mathcal{N}_i^k} v_u^{k,l}, \tag{2}$$

其中，N_u^k、N_i^k 分别是用户 u 和物品 i 的邻居节点。(l+1)表示在神经网络的第(l+1)层执行编码操作。特别地，我们利用原始用户和物品嵌入来定义 $v^{k,}{}_{u}{}^{0}$ 和 $v^{k,}{}_{i}{}^{0}$。由于单行为表示可能受到数据稀疏性问题的影响，我们提出进行跨类型多行为嵌入聚合，在保留上下文信息的同时应用多层变换矩阵。具体公式如下：

$$v_u = PReLU((v_u^0||, ..., ||v_u^l||, ..., ||v_u^L) \times W^l), \tag{3}$$

$$v_u^l = \sigma(W^u \times mean(v_u^{1,l} \oplus, ..., \oplus v_u^{k,l} \oplus, ..., \oplus v_u^{K,l})). \tag{4}$$

$W^u \in \mathrm{R}^{d \times d}$ 和 $W^l \in \mathrm{R}^{L\ d \times d}$ 是可训练的变换参数，其中 d 为潜在维度，L 为神经网络层数。 σ 定义为 Sigmoid 激活函数。物品聚合采用类似的操作。

3.1.2 多行为对比学习。 受对比学习策略的启发，我们希望利用多个视图构建不同的表征，并将其视为辅助信号，以缓解目标行为数据稀疏问题。同时，我们尝试通过对比策略，缩小同一用户不同多行为之间的差异，并扩大不同用户之间的差异。因此，一个简单的想法是将不同的行为视为不同的视图。具体而言，我们在不同的行为之间对用户嵌入进行对比学习，并通过不同的嵌入组合实现跨类型行为依赖编码，从而完成用户级信息增强。

对比学习的关键之一是从不同视图中提取有效的正负样本对。在我们的 KMCLR 中，我们随机选取用户 x 的不同辅助行为作为正样本对，而将用户 x 和 y 的视图采样为负样本对。因此，根据之前生成的用户嵌入，我们进一步得到正负样本对：$\left\{v_x^k,\ v_x^{k'}\right\}$ 和 $\left\{v_x^k,\ v_y^{k'}\right\}$，其中 $x,\ y \in \mathrm{U}$ 和 $x \neq y$。根据文献 [15],，我们基于 InfoNCE 损失定义了自监督对比损失，如下所示：

$$\mathcal{L}_{MulCL} = \sum_{k'=1}^{K} \sum_{x \in \mathcal{U}} -log \frac{exp(s(v_x^k, v_x^{k'})/\tau)}{\sum_{y \in \mathcal{U}} exp(s(v_x^k, v_y^{k'})/\tau)}. \tag{5}$$

τ 是用于控制 softmax 曲线平滑度的参数。s(~)表示用于反映相似度的成对距离函数

，用于衡量正负样本对。通过多行为对比学习任务，KMCLR 能够学习到更稳健的用户表示，捕捉目标行为与其他行为之间的潜在依赖关系，并区分不同用户的个人偏好。

3.2 知识增强模块

知识图谱作为辅助信息输入知识增强模块。KMCLR 利用不同的图嵌入技术，侧重于知识图谱中的合理性和语义信息，以获取不同的节点表示。基于每种图嵌入表示，我们从用户视角提出一种物品评分评估方法，通过保留低噪声的物品信息来构建用户-物品嵌入。这些处理后的数据将进一步用于根据对比学习任务优化物品级嵌入表示。

3.2.1 物品侧信息编码与聚合。 作为物品侧信息的补充，知识图谱的边上包含丰富的关系表征。在大多数情况下，知识图谱中邻居节点的重要性各不相同。为体现这种差异，受图注意力机制 [20], 启发，我们设计了一种基于注意力权重聚合邻居节点并获取物品表征的方法：

$$\mathcal{W}_{i,r,e} = \frac{f_{att}(v_i, v_r, v_e)}{\sum_{e' \in \mathcal{N}_i} f_{att}(v_i, v_r, v_{e'})}, \tag{6}$$

$$f_{att}(v_i, v_r, v_e) = exp[\sigma(W_1(v_i || v_r || v_e)) + b_1],$$

$$v_i^{l+1} = \sigma(W_2(v_i^l + \sum_{e \in \mathcal{N}_i} \mathcal{W}_{i,r,e} v_e) + b_2), \tag{7}$$

其中，$W_{i,r,e}$表示物品 i在关系 r下指向邻居节点$e \in N_i$的权重。 W_1, $W_2 \in R^{3d}$和 $b_1, b_2 \in R$均为可训练参数。 v_i^{l+1}表示物品 i经过第（l +1）次聚合后的嵌入。此处，我们用 v_i^0表示原始物品嵌入。

3.2.2 基于知识的增强与扩充。 如前所述，我们希望构建多个合适的视图用于对比学习。因此，我们提出两种不同的方法来生成知识表示，分别是平移距离模型 TransR [11] 和语义匹配模型 TATEC [5]。这两种表示分别关注知识图谱中三元组的合理性和潜在语义，从而获得关注重点各异的知识增强图。具体公式如下：

$$f_{td}(h, r, t) = -||M_r v_h + v_r - M_r v_t||_2^2, \tag{8}$$

$$f_{sm}(h, r, t) = v_h^T M_r v_t + v_h^T v_r + v_t^T v_r + v_h^T d D v_t. \tag{9}$$

$M_r \in R^{d \times d}$ 是从实体空间到 r的关系空间的投影矩阵，而 D 是所有不同关系共享的对角矩阵。 v_h, v_r, v_t表示知识图谱中的三元组嵌入。因此，我们通过初始化得到图的两种不同表征：G_{k1} 和 G_{k2}。然后，利用两种不同的损失函数来优化知识图谱的节点表示：

$$\mathcal{L}_{td} = \sum_{(h,r,t,t') \in \mathcal{G}_{k1}} -ln\sigma(f_{td}(h, r, t') - f_{td}(h, r, t)), \tag{10}$$

$$\mathcal{L}_{sm} = \sum_{(h,r,t,t') \in \mathcal{G}_{k2}} -ln\sigma(f_{sm}(h, r, t') - f_{sm}(h, r, t)), \tag{11}$$

其中，$(h, r, t_{\prime})$ 是知识图谱中不存在的三元组。通过上述方法，KMCLR 进一步从不同角度实现了知识表示的增强

尽管引入知识图谱能够补充推荐信息，但也会带来一些噪声。因此，受文献 [10, 35, 42], 启发，如果不同知识子图得到的节点表示相似，就说明该节点对结构变化不敏感，且具有较强的抗噪性。我们提出一种简单的方法来计算图结构一致性，以降低噪声信息的影响：

$$c = s(g_1(v_i), g_1'(v_i)); \qquad (g_1, g_1' \in \mathcal{G}_{k1}^{sub}), \tag{12}$$

$$c' = s(g_2(v_i), g_2'(v_i)); \qquad (g_2, g_2' \in \mathcal{G}_{k2}^{sub}). \tag{13}$$

其中，$(g_1,\ g_{\prime 1},\ g_2,\ g_{\prime 2})$ 是通过设置不同的随机种子，从 G_{k1} 和 G_{k2} 中采样得到的子图。 $s(\sim)$ 是用于计算所有物品节点一致性参数 $c \in R^{1 \times M}$ 的相似度函数。具体而言，我们通过公式（7）获得子图的节点表示 v_i。一般来说，节点的稳定性和抗噪性越强，其对应的分数 c就越高；该分数用作引导信息，以优化用户-物品交互图。

稳定节点有助于抵抗噪声，但不足以反映用户偏好。有些用户可能更喜欢与稳定性较低的节点交互。因此，在获得知识图谱中节点的一致性分数后，我们尝试从用户的角度调整该分数，并利用它来引导交互图中边的选择。我们设计了以下采样概率计算公式：

$$P_{u,i} = \sigma(v_u^T v_i) \odot c, \tag{14}$$

$$\hat{P_{u,i}} = (1 - Min\_Max(P_{u,i}))a + Min\_Max(P_{u,i})b. \tag{15}$$

$P_{u,\ i}$ 是根据用户交互和一致性分数 c得出的初始采样概率，而 $\odot$ 是通过广播机制进行的逐元素乘法。KMCLR 执行最小 - 最大归一化函数 $Min\_Max(\sim)$，将 $P_{u,\ i}$ 转换到区间 [a,b]，从而得到交互图的最终采样概率。根据该概率确定交互图中的边保留情况，进而获得两个用户-物品子图 G_{u1} 和 G_{u2}。

3.2.3 知识感知对比学习。 经过上述步骤，KMCLR 获得了两对侧重信息各不相同的视角图：（G_{u1}，G_{k1}）和（G_{u2}，G_{k2}）。根据公式（7），对物品的表征进行编码，以保留知识图谱的信息。随后，与多行为学习模块类似，我们使用 LightGCN 执行消息传播，并计算用户-物品图的嵌入。具体公式与公式（2）相同。

基于上述提到的两对视角，KMCLR 对视图特定的节点表征进行对比学习，将不同视图中的同一节点嵌入视为正样本对，将不同视图中的不同节点视为负样本对。与公式（5）类似，我们定义如下公式：

$$\mathcal{L}_{KCL} = \sum_{x \in \mathcal{U} \cup \mathcal{V}} -log \frac{exp(s(v_x^1, v_x^2)/\tau)}{\sum_{y \in \mathcal{U} \cup \mathcal{V}} exp(s(v_x^1, v_y^2)/\tau)}. \tag{16}$$

通过知识感知对比学习任务，KMCLR 可以利用外部知识图谱补充物品侧信息，降低外部噪声的影响，并在一定程度上缓解数据稀疏性问题。

3.3 联合学习模块

通过上述模块，我们获得了两种以不同方式生成的用户-物品嵌入：一种利用多行为信息，另一种利用知识图谱信息。这些从不同角度获得的嵌入包含侧重点各异的信息，因此需要以合理的方式进行组合。为此，我们分配一个组合权重 α，并通过实验探索最优组合结果。我们可以得到：

$$v_u = (1-\alpha)v_u^{mul} + \alpha v_u^{kg}, \qquad v_i = (1-\alpha)v_i^{mul} + \alpha v_i^{kg}. \tag{17}$$

在优化阶段，遵循经典排序模型 [17], ，KMCLR 使用贝叶斯个性化排序（BPR）推荐损失作为主任务损失，以进一步优化参数：

$$\mathcal{L}_{BPR} = -\sum_{u\in\mathcal{U}}\sum_{i\in\mathcal{N}_u}\sum_{j\notin\mathcal{N}_u} In\sigma(v_u^T v_i - v_u^T v_j), \tag{18}$$

其中，Nu 表示用户 u的观测交互集合。

在定义全部三种损失后，我们提出一种训练策略范式，以便更好地从不同视图中学习信息并进一步优化模型。具体而言：（1）首先，我们将在多行为学习模块和知识增强模块中分别训练两个对比学习模型，利用各自独立的训练数据学习这两个模块不同的初始参数空间。（2）然后，将两部分训练得到的节点嵌入与组合权重 α拼接。我们计算新节点嵌入的主模型 BPR 损失和对比学习损失，作为 KMCLR 的最终优化步骤。值得注意的是，经过研究，我们决定在多行为学习模块中采用 LightGCN 作为主模型。具体训练范式如下：

$$\begin{aligned} argmin \triangleq main\_opt\{&mul\_opt(L^{mul}, V^{mul}), \\ &kg\_opt(L^{kg}, V^{kg}), V^{main}\}. \end{aligned} \tag{19}$$

其中， $\_opt$ 是参数优化器， L 和 V 分别是相应模块的损失和节点表示集合。其中，对于损失 L，我们给出如下定义：

$$L = \mathcal{L}_{BPR} + \lambda 1\mathcal{L}_{cl} + \lambda 2||\Omega||_2^2, \tag{20}$$

其中， Ω 是可学习模型参数，而 $\lambda 1$ 和 $\lambda 2$ 用于控制自监督信号和正则化项的权重。

3.4 模型复杂度分析

我们从以下几个方面分析 KMCLR 的复杂度：(1) 在多行为学习模块中，轻量级神经网络架构的开销为 $O(L\times K\times|\Theta^+|\times d)$，其中包含 L 个网络层、K 种行为类型、 $|\Theta^+|$ 条交互边以及 d 的隐层维度。跨行为类型的信息聚合开销为 O $L\times(\,(\,)\,)$。计算 $K\times$ $I+J$ $\times d$ InfoNCE 损失的复杂度为 (O $B\times$ $K\times|\Theta^+|\times d$ B 2)，其中 表示每个训练轮次的样本量。( ) 在知识增强模块中，信息聚合操作的开销为 $O(|R|\times d)$，其中 $|R|$ 表示 G_v 中的关系数量。对于每一对视角图的生成，KMCLR 的开销为 $O(|\Theta^+|\times d^2+|\Theta^+|\times d\times L)$。基于 InfoNCE 的损失计算复杂度为 $O(B\times d\times(I+J))$。与现有模型相比，KMCLR 以略微增加复杂度为代价提升了性能。

表1：数据集统计信息

数据集	用户	物品	交互	交互行为类型
Yelp	19,800	22,734	1,400,002	{不喜欢, 中立, 小费, 喜欢}
天猫	31,882	31,232	1.451,219	{页面浏览, 收藏, 购物车, 购买}
零售	147,894	99,037	1,584,238	{收藏, 购物车, 购买}

4 实验

本节通过大量实验评估 KMCLR 的性能，并回答以下问题：（**RQ1**）与其他推荐方法相比，KMCLR 的表现如何？（**研究问题2**）KM- CLRonperformance 中不同模块分别有何作用？（**RQ3**）KMCLR 如何有效缓解推荐中的数据稀疏性问题？（**RQ4**）不同的超参数设置会如何影响性能？（**RQ5**）KMCLR 如何缓解额外信息所导致的噪声问题？

4.1 实验数据集

我们在三个真实世界数据集上进行实验，以验证 KMCLR 的有效性。**Yelp：** 该数据集由美国知名商业点评网站收集，涵盖餐厅、购物中心、酒店等领域，通常用于商业场所推荐。根据 [31], 的设置，我们考虑了四种行为（即，不喜欢、中立、小费、喜欢）。**天猫：** 该数据集由中国最大的电子商务平台之一收集。在该数据集中，用户交互包括页面浏览、标记为收藏、加入购物车 和购买。**零售：** 这是一个关于在线零售场景的数据集，包含显式的多类型用户-物品交互。我们提取以下三种行为作为训练数据，即标记为收藏、加入购物车 和购买。表1展示了上述数据集的详细统计信息。此外，参照以往研究，我们在实验中采用了文献 [31]构建的知识图谱。

4.2 对比方法

我们将 KMCLR 与来自不同研究方向的多种基线方法进行比较，具体如下：

基于协同过滤的方法：

- **BPR [17]：** 这是一种传统的协同过滤方法，使用成对排序损失对物品进行个性化排序。
- **LightGCN [7]：** 它使用图神经网络进行协同过滤，并简化了消息传播过程中的卷积操作。
- **AutoRec [19]：** 这是一种基于自编码器的模型，可将用户-物品交互映射到隐藏的低维空间中。
- **NGCF [25]：** 这是一种基于图神经网络协同过滤的消息传递框架，利用高阶连接性进行聚合。

知识感知推荐方法：

- **KGAT [23]：** 它设计了一种基于知识协同图的注意力消息传播框架，用于研究语义关系之间的高阶连通性。

- **KGCL [35]：** 它利用对比学习作为辅助信息，在联合自监督学习范式下，将知识图谱学习与用户-物品交互建模相结合。

表2：不同数据集上的 HR@10 和 NDCG@10 性能比较

Data	指标	BPR	LightGCN	AutoRec	NGCF	KGAT	KGCL	NMTR	MATN	MBGCN	KHGT		CML	KMCLR
Yelp	HR	0.7435	0.7884	0.7592	0.7903	0.8211	0.8331	0.7880	0.8210	0.7962	0.8767	0.8774	**0.8897**
	NDCG	0.4497	0.4993	0.4705	0.5063	0.5362	0.5516	0.4673	0.5331	0.5033	0.5970	0.5965	**0.6038**
天猫	HR	0.2443	0.3418	0.3274	0.3288	0.3853	0.4027	0.3623	0.4302	0.3910	0.4032	0.5185	**0.5671**
	NDCG	0.1501	0.2048	0.1903	0.1964	0.2219	0.2293	0.2097	0.2437	0.2261	0.2351	0.3055	**0.3540**
零售	HR	0.2608	0.3065	0.2779	0.3027	0.3485	0.3502	0.3112	0.3490	0.3137	0.4199	0.4256	**0.4557**
	NDCG	0.1653	0.1847	0.1683	0.1844	0.2191	0.2197	0.1869	0.2183	0.1904	0.2471	0.2503	**0.2735**

多行为推荐方法：

• **NMTR [4]：** 这是一个多任务推荐框架，可以对多种行为类型进行级联预测。

• **MATN [30]：** 该方法利用注意力网络和记忆单元，学习多种行为之间的交互依赖关系。

• **MBGCN [9]：** 该模型基于图卷积网络，通过对用户的多种行为进行建模，在统一图上传播行为感知嵌入。

• **KHGT [31]：** 该方法引入基于Transformer的方法来建模多行为，重点关注时间信息和辅助知识信息，并通过图注意力网络对行为嵌入进行建模。

• **CML [26]：** 该方法将对比学习引入多行为推荐，并提出元对比编码，使模型能够学习个性化行为特征。

4.3 参数设置

我们使用 PyTorch 实现 KMCLR，并将所有模块中用户和物品的嵌入维度设为 32。知识增强模块和多行为学习模块分别采用正态方法和 Xavier初始化方法进行嵌入初始化。我们使用 Adma优化器优化所有模型，上述不同模块的学习率分别为 $1e^{-3}$ 和 $3e^{-4}$。我们采用 L2 正则化，并将衰减权重设为 $\{0.05,0.01,0.005,0.001,0.0005,0.0001\}$，以学习嵌入。模型采用的消息传播层数从 {1,2,3,4} 中选择。组合权重 α从范围 $\{0.1,0.2,0.3,0.4\}$ 中选取。对于对比基线实验，参数按照原文进行设置。

4.4 性能验证（RQ1）

表2展示了所有基线方法在不同数据集上的性能评估结果，我们总结出以下观察结论：

与其他所有基线模型相比，KMCLR 在每个数据集上都取得了最佳性能，这证实了我们模型的有效性。由于不同数据集在数据规模和稀疏性方面存在较大差异，这也证明了 KMCLR 具有良好的泛化能力。我们主要将性能的显著提升归因于以下两个方面：（1）得益于多种行为信息和额外知识图谱（KG）的引入，模型能够从多个方面充分捕捉个性化信息，并将其作为信号来指导目标行为的推荐。（2）由于引入了辅助自监督任务，模型能够挖掘个体在高层特征方面的偏好，从而清晰地区分个体之间的信息梯度。

我们可以发现，知识感知推荐和多行为推荐始终优于基于协同过滤的单行为推荐，这意味着在个性化建模中引入额外的辅助信息是有益的，在一定程度上可以弥补单一行为中的数据稀疏问题。此外，在各种基线方法中，CML通常表现最佳。这一结果表明，在多行为推荐中引入对比学习，能够使模型更好地学习个体行为之间的共性和差异，并通过不同语义引导更精细的推荐。此外，KHGT在大多数情况下也取得了次优结果，证明了联合考虑多行为视图和知识图谱视图的有效性。

表3：消融实验结果

模型 \ 数据集	Yelp		天猫		零售	
	HR	NDCG	HR	NDCG	HR	NDCG
w/o-Mcl	0.8352	0.5749	0.4583	0.2645	0.3612	0.2157
w/o-Kcl	0.8687	0.5916	0.5231	0.3064	0.4247	0.2513
去除NorT	0.8701	0.5943	0.5339	0.3106	0.4268	0.2502
KMCLR	**0.8897**	**0.6038**	**0.5671**	**0.3540**	**0.4557**	**0.2735**

4.5 模型消融实验（研究问题2）

为探究不同组件对性能提升的影响并证明其有效性，我们考虑了 KMCLR 的三个变体，并设计了以下消融实验：

• **w/o-Mcl：** 为研究多行为信息对模型的影响，我们提出了一个变体 w/o-Mcl，该变体禁用了多行为学习模块，仅利用单一目标行为的信息进行嵌入生成和学习。如表3所示，与完整的 KMCLR 相比，移除多行为学习模块的版本在两项指标上的表现均显著下降。这是因为同一用户产生的不同行为可以从多个角度刻画其个体偏好。利用信息对比来建模不同行为之间的粗粒度共性，有助于 KMCLR 学习更好的表征，同时区分个体之间的细粒度差异。上述信息还可以作为补充信息，用于应对数据稀疏性问题。

• **w/o-Kcl:** 为确认引入知识图谱有助于

增强物品侧信息，并对目标推荐发挥积极作用，我们设计了另一个变体 w/o-Kcl。该变体通过禁用知识增强模块，使 KMCLR 退化为一个简单的多行为对比学习模型。实验结果表明，将知识图谱作为辅助信息引入能够提升模型性能，这符合常理。尽管引入知识图谱可能会额外带来噪声信息，但我们设计的知识增强模块通过筛选稳定节点，将这种影响降至最低。同时，KMCLR 对知识图谱进行处理，生成两个侧重点不同的图，以从不同角度强化知识对最终推荐的作用。

• **去除NorT：** 在模型训练阶段，我们提出了一种联合训练范式，以增强 KMCLR 的学习效果。为验证其效果，我们在消融实验中采用常规训练策略，即直接优化两个对比损失与 BPR 损失的线性加权和。这种常规优化未考虑辅助任务与主任务之间的整合方式，也忽略了不同自监督学习对主任务的影响。相比之下，KMCLR 的策略是先分别训练不同视图的节点嵌入，然后进行集成优化。通过多轮优化，辅助信息从底层融入节点嵌入。实验结果表明，我们的训练策略更有利于目标行为的推荐。

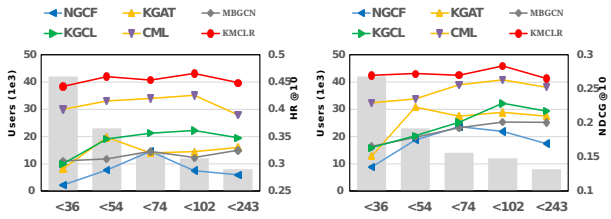

(a) 零售 HR@10 (b) 零售 NDCG@10

图 2：KMCLR 与基线方法在零售数据上不同数据稀疏程度下的性能。

4.6 缓解数据稀疏性的性能（RQ3）

由于交互数据稀疏性在现实场景中普遍存在， [41], 因此缓解这一问题的能力成为评估推荐系统的一项指标。我们进行了额外实验，以验证模型在稀疏程度不同的交互数据上的表现。我们遵循 [31] 中的类似设置，为零售数据集生成稀疏程度不同的数据集。如图 2 所示，横轴表示用户交互次数——

量，y 轴表示推荐准确率。

我们得出以下结论：(1) 基于协同过滤的模型（NGCF）受到数据稀疏性的显著影响，因此结合额外信息（例如，多行为信息、知识信息）可以在一定程度上缓解这一影响。(2) 与仅引入辅助信息的模型（KGAT、MBGCN）相比，结合对比学习的模型（KGCL、CML）效果更好，这表明对比学习能够使模型维持行为异质性和知识语义多样性，并借助自监督范式实现这一点。(3) 与其他方法相比，KMCLR 在处理不同稀疏程度的数据时表现稳定。结果表明，随着数据变得更加稀疏，我们的方法与其他竞争方法之间的性能差距也愈发显著，这证明联合引入多行为信息和知识图谱信息能够更好地缓解数据稀疏性，并使模型通过结合上下文信息（例如，点击、标记为收藏）和辅助信息来考虑多视角用户偏好。

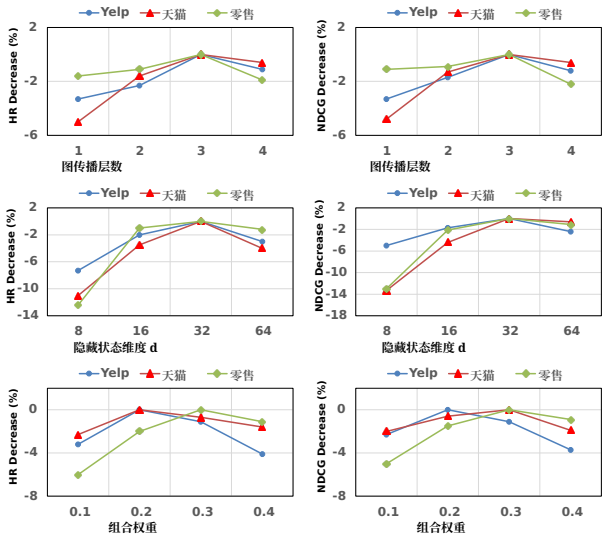

图3：KMCLR 的超参数分析。

4.7 超参数分析（RQ4）

为了研究超参数设置对 KMCLR 的影响，我们进行了实验，探索在不同配置下，隐藏状态维度 d、图传播层 L 和组合权重 α 对结果的影响。结果如图3所示，其中 y 轴表示在其他设置下的性能相较于最优设置时的最佳性能下降或提升的程度。

• **隐藏状态维度 d：** 我们将嵌入维度设置为 {8， 16， 32， 64}，并保持其他最优超参数不变。可以观察到，随着嵌入维度从 8 增加到 32，模型性能有所提升。然而，嵌入维度越大并不总是意味着模型表示能力越强，还可能导致模型过拟合。

• **图传播层 L：** 通过堆叠图传播层，模型能够捕获来自高阶邻居的潜在依赖关系，充分学习高阶节点之间的协作关系。实验结果表明，当 L 为 3 时，模型效果最佳。进一步堆叠更多传播层可能会引入更多噪声信号，从而导致过平滑 [14]。

• **组合权重 α：** 为了区分多行为信息与知识图谱信息的重要性，我们将 α 设定在区间 {0.1, 0.2,0.3,0.4}内。实验结果表明，

当 $0.2 \leq \alpha \leq 0.3$ 时，模型效果最佳。这证明，过多的知识图谱信息会引入额外的噪声，而过少则会导致信息增强不足。

4.8 缓解噪声影响的性能（RQ5）

尽管额外的辅助信息有助于提升推荐性能，但也会引入噪声信号。无论是在多行为交互图还是知识图谱中，都存在一些会干扰最终推荐的无效节点。因此，在利用辅助信息增强信息的同时，KMCLR 也考虑采用方法来降低这些噪声信号的影响。具体而言，对于多行为交互图，我们设置一系列随机丢弃概率，以探索不同数据集下的最优采样策略。通过调整公式15中的区间参数 $[a, b]$，KMCLR 实现了对知识图谱的自动降噪采样。区间范围反映了模型对知识图谱噪声信号的容忍度。我们在两个数据集上进行了模型降噪实验，实验结果如图4所示。横坐标表示多行为信息的随机丢弃率，纵坐标表示知识噪声容忍度的下限。

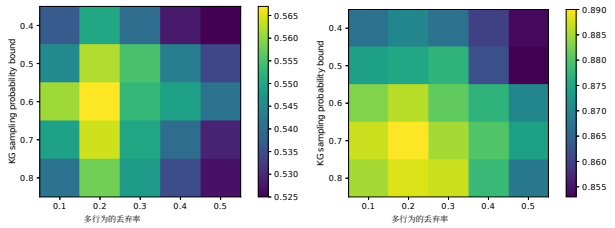

(a) 天猫 HR@10 (b) Yelp HR@10

图4：缓解噪声的参数设置。

5 相关工作

5.1 多行为推荐

为了使推荐系统能够更全面地表达用户偏好，许多方法提出利用用户/物品的辅助信息来表示各种关系 [12]。因此，近期研究开始关注多行为推荐，尝试通过各类额外的行为信息来辅助目标行为的推荐。例如，研究 [30] 通过设计注意力机制来刻画行为之间的关系。MBGCN [9]使用图卷积网络学习行为之间的相似性，以区分个体习惯。MB-GMN [32] 将元学习与多行为消息相结合，从低秩视角探索行为背后的隐式嵌入。我们的模型则通过对比不同的行为来挖掘内在的语义关系，充分考虑行为认知之间的相关性，并以辅助信号的形式弥补数据稀疏问题。

5.2 基于知识图谱的推荐

近年来，知识图谱已成为增强现有推荐系统框架的重要数据源，因此衍生出了一系列基于知识图谱的推荐系统方法 [21, 40]。例如，经典的 KGAT 模型 [23] 整合了知识图谱信息和交互图信息，通过图注意力网络进行推荐预测。KHGT [31] 则尝试将物品侧的知识图谱信息引入多行为推荐，并将其作为一列节点嵌入融合到整个交互物品表示中。此外，其他方法尝试利用知识图谱信息增强语义表示，通过映射或其他方式转换图信息，也取得了一些成果 [33, 36]。

5.3 用于推荐的对比学习

对比学习旨在通过前置任务区分对象之间的相似性与差异，并通过对比来自不同视图的正负样本来学习各自的特征。研究已证明，对比学习在计算机视觉 [1],自然语言处理 [3], 等多个领域都十分有效。近年来，一些研究尝试将自监督学习引入推荐系统，并取得了一定成果 [13, 16, 28]。SMIN [13] 提出了一种基于元关系的异构图神经网络，通过自监督学习最大化局部特征与全局特征之间的互信息，从而进行联合训练。研究 [39] 利用基于自注意力机制的自监督学习进行序列推荐。该方法利用原始数据之间的相关性构建自监督信号，并通过预训练方法增强数据表示，以提升序列推荐效果。我们的工作则侧重于探索行为语义并挖掘知识表示，提出了一种结合多行为建模与知识建模的新型对比学习框架。

6 结论

在这项工作中，我们提出了 KMCLR，这是一种基于知识增强、用于多行为对比学习的新型推荐框架。具体而言，我们将多行为信息和知识图谱信息共同引入推荐系统，以增强用户行为侧和物品侧的信息，从而缓解目标行为数据稀疏问题。此外，通过设计两个对比学习任务和一种联合训练范式，KMCLR 能够从多个角度学习个体偏好，同时考虑不同行为和视图之间的共性与差异。在多个数据集上的大量实验结果表明，与各种最先进的方法相比，KMCLR 有效性显著。未来一个值得探索的方向是进一步开发高效模型，以应对引入额外信息所导致的噪声信号问题。

7 致谢

本研究得到国家自然科学基金（62003379）、中国“十四五”民用航天预研项目（D020101）、澳大利亚研究理事会未来研究员项目（FT210100624）、探索项目（DP190101985）以及南京航空航天大学研究生科研与实践创新计划（xcxjh20221605）的资助。

参考文献

[1] Yu Deng、Jiaolong Yang、Dong Chen、Fang Wen 和 Xin Tong。2020。通过三维模仿对比学习实现解耦且可控的人脸图像生成。载于 IEEE/CVF 计算机视觉与模式识别会议论文集。5154–5163。[2] Chao Du、Chongxuan Li、Yin Zheng、Jun Zhu 和 Bo Zhang。2018。基于用户-物品协同自回归模型的协同过滤。载于 AAAI人工智能会议论文集，第32卷。[3] Hao Fu、Shaojun Zhou、Qihong Yang、Junjie Tang、Guiquan Liu、Kaikui Liu 和 Xiaolong Li。2021。LRC-BERT：用于自然语言理解的潜在表征对比知识蒸馏。载于 AAAI人工智能会议论文集，第35卷。12830–12838。[4] Chen Gao、Xiangnan He、Dahua Gan、Xiangning Chen、Fuli Feng、Yong Li、Tat-Seng Chua 和 Depeng Jin。2019。基于多行为数据的神经多任务推荐。载于2019年 IEEE 第35届国际数据工程会议（ICDE）。IEEE，1554–1557。[5] Alberto García-Durán、Antoine Bordes 和 Nicolas Usunier。2014。有效融合二元和三元交互以建模多关系数据。载于欧洲机器学习与数据库知识发现联合会议。Springer，434–449。[6] Zhabiz Gharibshah 和 Xingquan Zhu。2021。在线广告中的用户响应预测。ACM计算调查（CSUR）54卷3期（2021），1–43。[7] Xiangnan He、Kuan Deng、Xiang Wang、Yan Li、Yongdong Zhang 和 Meng Wang。2020。LightGCN：简化并增强用于推荐的图卷积网络。载于第43届国际ACM SIGIR信息检索研究与发展会议论文集。639–648。[8] Xiangnan He、Lizi Liao、Hanwang Zhang、Liqiang Nie、Xia Hu 和 Tat-Seng Chua。2017。神经协同过滤。载于第26届国际万维网会议论文集。173–182。[9] Bowen Jin、Chen Gao、Xiangnan He、Depeng Jin 和 Yong Li。2020。基于图卷积网络的多行为推荐。载于第43届国际ACM SIGIR信息检索研究与发展会议论文集。659–668。[10] Weike Jin、Zhou Zhao、Pengcheng Zhang、Jieming Zhu 和 Yueting Zhuang。2021。用于视频-文本检索的层次化跨模态图一致性学习。载于 SIGIR '21：第44届国际ACM SIGIR信息检索研究与发展会议。[11] Yankai Lin、Zhiyuan Liu、Maosong Sun、Yang Liu 和 Xuan Zhu。2015。学习用于知识图谱补全的实体和关系嵌入。载于第二十九届AAAI人工智能会议。[12] Siwei Liu、Iadh Ounis、Craig Macdonald 和 Zaiqiao Meng。2020。用于冷启动推荐的异构图神经模型。载于第43届国际ACM SIGIR信息检索研究与发展会议论文集。2029–2032。[13] Xiaoling Long、Chao Huang、Yong Xu、Huance Xu、Peng Dai、Lianghao Xia 和 Liefeng Bo。2021。基于自监督元图互信息网络的社交推荐。载于第30届ACM信息与知识管理国际会议论文集。1160–1169。[14] Dongsheng Luo、Wei Cheng、Wenchao Yu、Bo Zong、Jingchao Ni、Haifeng Chen 和 Xiang Zhang。2021。学习丢弃：通过拓扑去噪实现鲁棒图神经网络。载于第14届ACM网络搜索与数据挖掘国际会议论文集。779–787。[15] Aaron van den Oord、Yazhe Li 和 Oriol Vinyals。2018。基于对比预测编码的表征学习。arXiv预印本 arXiv:1807.03748（2018）。[16] Ruihong Qiu、Zi Huang、Hongzhi Yin 和 Zijian Wang。2022。针对序列推荐中表征退化问题的对比学习。载于第15届ACM网络搜索与数据挖掘国际会议论文集。813–823。[17] Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。2012。BPR：基于隐式反馈的贝叶斯个性化排序。arXiv预印本 arXiv:1205.2618（2012）。[18] Suvash Sedhain、Aditya Krishna Menon、Scott Sanner 和 Lexing Xie。2015。AutoRec：自编码器与协同过滤的结合。载于第24届国际万维网会议论文集。111–112。[19] Suvash Sedhain、Aditya Krishna Menon、Scott Sanner 和 Lexing Xie。2015。AutoRec：自编码器与协同过滤的结合。载于第24届国际万维网会议论文集。111–112。[20] Petar Velickovic、Guillem Cucurull、Arantxa Casanova、Adriana Romero、Pietro Lio 和 Yoshua Bengio。2017。图注意力网络。stat 1050（2017），20。[21] Hongwei Wang、Fuzheng Zhang、Mengdi Zhang、Jure Leskovec、Miao Zhao、Wenjie Li 和 Zhongyuan Wang。2019。用于推荐系统的知识感知图神经网络及标签平滑正则化。载于第25届ACM SIGKDD知识发现与数据挖掘国际会议论文集。968–977。[22] Jianling Wang、Raphael Louca、Diane Hu、Caitlin Cellier、James Caverlee 和 Liangjie Hong。2020。情人节到了，该去购物了：购物场景与电子商务中的序列推荐。载于第13届国际网络搜索与数据挖掘会议论文集。645–653。[23] Xiang Wang、Xiangnan He、Yixin Cao、Meng Liu 和 Tat-Seng Chua。2019年。Kgat：用于推荐的知识图谱注意力网络。载于第25届ACM SIGKDD知识发现与数据挖掘国际会议论文集。950–958。[24] Xiang Wang、Xiangnan He、Meng Wang、Fuli Feng 和 Tat-Seng Chua。2019年。神经图协同过滤。载于第42届国际ACM SIGIR信息检索研究与发展会议论文集。165–174。[25] Xiang Wang、Xiangnan He、Meng Wang、Fuli Feng 和 Tat-Seng Chua。2019年。神经图协同过滤。载于第42届国际ACM SIGIR信息检索研究与发展会议论文集。165–174。[26] Wei Wei、Chao Huang、Lianghao Xia、Yong Xu、Jiashu Zhao 和 Dawei Yin。2022年。结合行为多样性的推荐对比元学习。载于第15届ACM网络搜索与数据挖掘国际会议论文集。1120–1128。[27] Yinwei Wei、Xiang Wang、Liqiang Nie、Xiangnan He 和 Tat-Seng Chua。2020年。用于隐式反馈多媒体推荐的图精炼卷积网络。载于第28届ACM多媒体国际会议论文集。3541–3549。[28] Jiancan Wu、Xiang Wang、Fuli Feng、Xiangnan He、Liang Chen、Jianxun Lian 和 Xing Xie。2021年。用于推荐的自监督图学习。载于第44届国际ACM SIGIR信息检索研究与发展会议论文集。726–735。[29] Yiqing Wu、Ruobing Xie、Yongchun Zhu、Xiang Ao、Xin Chen、Xu Zhang、Fuzhen Zhuang、Leyu Lin 和 Qing He。2022年。用于推荐的多视图多行为对比学习。载于数据库系统高级应用国际会议论文集。Springer，166–182。[30] Lianghao Xia、Chao Huang、Yong Xu、Peng Dai、Bo Zhang 和 Liefeng Bo。2020年。通过记忆增强型Transformer网络进行推荐的多路行为关系学习。载于第43届国际ACM SIGIR信息检索研究与发展会议论文集。2397–2406。[31] Lianghao Xia、Chao Huang、Yong Xu、Peng Dai、Xiyue Zhang、Hongsheng Yang、Jian Pei 和 Liefeng Bo。2021年。用于多行为推荐的知识增强型分层图Transformer网络。载于AAAI人工智能会议论文集，第35卷。4486–4493。[32] Lianghao Xia、Yong Xu、Chao Huang、Peng Dai 和 Liefeng Bo。2021年。用于多行为推荐的图元网络。载于第44届国际ACM SIGIR信息检索研究与发展会议论文集。757–766。[33] Xin Xin、Xiangnan He、Yongfeng Zhang、Yongdong Zhang 和 Joemon Jose。2019年。关系协同过滤：对用于推荐的多种物品关系进行建模。载于第42届国际ACM SIGIR信息检索研究与发展会议论文集。125–134。[34] Hong-Jian Xue、Xinyu Dai、Jianbing Zhang、Shujian Huang 和 Jiajun Chen。2017年。推荐系统的深度矩阵分解模型。载于IJCAI，第17卷。澳大利亚墨尔本，3203–3209。[35] Yuhao Yang、Chao Huang、Lianghao Xia 和 Chenliang Li。2022年。用于推荐的知识图谱对比学习。arXiv预印本 arXiv:2205.00976（2022年）。[36] Fuzheng Zhang、Nicholas Jing Yuan、Defu Lian、Xing Xie 和 Wei-Ying Ma。2016年。用于推荐系统的协同知识库嵌入。载于第22届ACM SIGKDD知识发现与数据挖掘国际会议论文集。353–362。[37] Jiani Zhang、Xingjian Shi、Shenglin Zhao 和 Irwin King。2019年。Star-GCN：用于推荐系统的堆叠与重构图卷积网络。arXiv预印本 arXiv:1905.13129（2019年）。[38] Chang Zhou、Jinze Bai、Junshuai Song、Xiaofei Liu、Zhengchao Zhao、Xiusi Chen 和 Jun Gao。2018年。ATRANK：基于注意力的用户行为建模推荐框架。载于第三十二届AAAI人工智能会议。[39] Kun Zhou、Hui Wang、Wayne Xin Zhao、Yutao Zhu、Sirui Wang、Fuzheng Zhang、Zhongyuan Wang 和 Ji-Rong Wen。2020年。S3-rec：通过互信息最大化进行序列推荐的自监督学习。载于第29届ACM信息与知识管理国际会议论文集。1893–1902。[40] Qiannan Zhu、Xiaofei Zhou、Jia Wu、Jianlong Tan 和 Li Guo。2020年。用于推荐的知识感知注意力推理网络。载于AAAI人工智能会议论文集，第34卷。6999–7006。[41] Yongchun Zhu、Zhenwei Tang、Yudan Liu、Fuzhen Zhuang、Ruobing Xie、Xu Zhang、Leyu Lin 和 Qing He。2022年。跨域推荐中用户偏好的个性化迁移。载于第15届ACM网络搜索与数据挖掘国际会议论文集。1507–1515。[42] Chenyi Zhuang 和 Qiang Ma。2018年。用于基于图的半监督分类的双图卷积网络。载于2018年万维网大会论文集。499–508。