

# 多层次图间对比增强的知识感知传播推荐算法<sup>①</sup>

樊海玮, 张朝亮, 牛新阳, 万青松, 邓玉莲

(长安大学 信息工程学院, 西安 710064)

通信作者: 张朝亮, E-mail: [clzhang0422@163.com](mailto:clzhang0422@163.com)



**摘要:** 传统的知识感知传播推荐算法中存在高阶特征相关度低、信息利用不平衡以及噪声引入问题。提出一种多层次图间知识增强对比学习的知识感知传播推荐算法 (MCLK-KE), 通过构建增强视图, 并利用自监督掩码重建预训练技术, 提取关键三元组的更深层信息, 有效抑制了噪声信号。算法实现了知识与交互信号的均衡利用, 并以图间对比强化了特征表达, 捕捉到全局范围内的有效节点属性。多任务训练通过联合训练推荐预测、对比学习和掩码重建任务, 提升模型性能。在 3 个公开数据集上, MCLK-KE 与最佳基线模型对比 AUC 指标最大提升了 3.3%, F1 值最高增长了 5.3%。

**关键词:** 知识图谱; 知识增强; 对比学习; 知识感知传播; 掩码重建

引用格式: 樊海玮, 张朝亮, 牛新阳, 万青松, 邓玉莲. 多层次图间对比增强的知识感知传播推荐算法. 计算机系统应用, 2025, 34(2):49–60. <http://www.c-s-a.org.cn/1003-3254/9753.html>

## Contrastive Enhancement in Multi-level Graph for Knowledge-aware Propagation Recommender Algorithm

FAN Hai-Wei, ZHANG Chao-Liang, NIU Xin-Yang, WAN Qing-Song, DENG Yu-Lian

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

**Abstract:** Traditional algorithms for knowledge-aware propagation recommendation face challenges including low correlation of higher-order features, unbalanced information utilization, and noise introduction. To address these challenges, this study proposes a multi-level contrastive learning for knowledge-aware propagation recommender algorithm utilizing knowledge enhancement (MCLK-KE). By constructing enhanced views and utilizing mask reconstruction-based self-supervised pre-training, the algorithm extracts deeper information from key triples to effectively suppress noise signals. It achieves a balanced utilization of knowledge and interactive signals while enhancing feature representation by comparing graphs to capture effective node attributes globally. Multi-task training significantly improves model performance by incorporating recommendation prediction, contrastive learning, and mask reconstruction tasks. In tests on three publicly available datasets, MCLK-KE demonstrates a maximum increase of 3.3% in AUC and 5.3% in F1 scores compared to the best baseline model.

**Key words:** knowledge graph; knowledge enhancement; contrastive learning; knowledge-aware propagation; mask reconstruction

知识感知推荐是通过将知识图谱作为辅助信息引入推荐模型<sup>[1]</sup>, 利用其丰富的语义和结构信息, 增强嵌

入表示学习能力. 特别是, 知识感知传播推荐具备高阶关系学习能力, 能够探索和利用知识图谱中的多跳实

① 收稿时间: 2024-07-11; 修改时间: 2024-08-01; 采用时间: 2024-08-13; csa 在线出版时间: 2024-12-13

CNKI 网络首发时间: 2024-12-13

体关系和属性信息。这类算法不仅能捕获局部的实体属性，还能整合更广泛的上下文信息，加深对整个知识图谱的理解。

传统知识感知推荐是基于深度神经网络，主要关注用户与项目的直接交互，未充分挖掘高阶交互信息。此后众多学者提出基于传播的知识感知推荐方法，借助图神经网络探索高阶交互模式，处理结构化交互信息，分析多跳邻居关系以挖掘潜在联系，更准确地描述了用户偏好和项目特征，但存在异构信息结构不平衡问题，导致模型过度关注噪声而忽略关键信息。

知识感知推荐算法引入对比学习这一自监督学习范式，从无标签样本数据学习目标，虽然在监督信号稀疏问题<sup>[2]</sup>方面有一定进展，但还存在3方面不足：(1)高阶特征的语义相关性低。随着传播层数增多，实体间的语义关联减弱<sup>[3]</sup>，应高效提取高阶特征<sup>[4]</sup>，防止信息传播中丢失。(2)噪声引入问题。知识图谱虽提供丰富信息，但引入的噪声使模型学到的特征表示偏离真实情况。(3)信息利用不平衡问题<sup>[4]</sup>。模型处理用户项目交互与知识信息时，因异构结构不平衡，降低了对关键交互信号的关注，放大了噪声影响<sup>[5]</sup>。

综上，本文提出多层次图间知识增强对比学习的知识感知传播推荐算法 (multi-level contrastive learning for knowledge-aware propagation recommender algorithm utilizing knowledge enhancement, MCLK-KE)。算法引入自监督的掩码重建范式预训练自编码器，可使其关注重要的三元组高阶信息，忽略噪声信号。另外，还引入多层次对比学习范式，其中通过图内对比学习平衡利用知识信号与交互信号，通过图间对比学习捕获全局范围内的有效节点特征，从而增强特征表示能力。在3个公开数据集中开展了对比实验，验证了该模型的有效性。

## 1 相关研究

### 1.1 知识感知推荐研究现状

知识感知推荐模型按数据处理策略分基于嵌入、连接、传播这3种。

基于嵌入的推荐算法将知识图谱的实体和关系映射至低维向量空间，为下游应用给予支撑。Zhang等<sup>[6]</sup>提出的CKE融合多种描述来增强用户偏好，但难以有效捕捉复杂交互，推荐性能不佳。Wang等<sup>[7]</sup>提出的MKR

利用交叉压缩单元结合任务来实现特征共享和高阶交互建模，强化个性化，然而交叉压缩单元限制了处理复杂交互的灵活性与效率。

基于路径的推荐算法构建多跳路径规则，分析路径偏好以揭示项目和用户的状况。Chen等<sup>[8]</sup>提出的TMR模型动态利用时间维度模拟交互关系，用注意力机制评估路径重要性，但在时间信息少的环境应用中受限。Wang等<sup>[9]</sup>提出的KPRN模型挖掘路径顺序依赖并用长短期记忆神经网络编码，用加权池化区分路径重要性，但在处理大规模知识图谱时计算效率和资源消耗方面待优化。

基于传播的推荐算法借鉴图神经网络的概念，采用广度优先搜索策略，通过限制跳数或采样邻居节点关系来提取知识图谱的特征。Wang等<sup>[10]</sup>提出的KGAT模型用递归传播邻居节点嵌入优化节点嵌入，引入注意力机制区分邻居贡献度，但在处理大规模图数据时计算复杂，处理长尾节点存在挑战。Wang等<sup>[11]</sup>提出的KGIN模型考虑用户意图与物品相互作用，引入关系路径感知聚合策略提升性能和可解释性。

### 1.2 图对比学习研究现状

图对比学习主要分为节点级、边级、图级这3类。

节点级方面：Qiu等<sup>[12]</sup>提出了图神经网络预训练框架GCC，通过将图表示学习构建为跨网络子图识别任务，并采用对比学习技术，增强图神经网络对可迁移的结构性表示学习能力。Hassani等<sup>[13]</sup>提出多视图对比表示学习方法CMVG，该方法通过对一阶邻居和图扩散的编码获得最优性能。

边级方面：Hu等<sup>[14]</sup>提出的GPT-GNN模型通过自监督式属性图生成任务对GNN进行预训练，旨在综合捕获图的结构特征与节点属性。Pan等<sup>[15]</sup>提出一种对抗图正则化图编码器ARGE。其结合了图卷积网络和对抗训练机制，旨在为图数据生成稳健的嵌入表示。

图级方面：You等<sup>[16]</sup>提出一种联合增强优化方法JOAO。通过双层优化自动选择数据增强方法，提升了GraphCL的通用性与易用性。Sun等<sup>[17]</sup>提出基于图神经网络的方法SUGAR。它通过子图神经网络重构“骨架图”，采用三级结构保留图信息，借助强化池化模块选择显著子图以提高泛化能力。利用自监督互信息机制区分子图表示并关注全局结构。这些机制使该方法既能捕捉局部也能理解全局属性，自适应识别关键子

图，并提供解释性分析。

## 2 MCLK-KE 算法

### 2.1 设计思路

基于对比学习的知识感知推荐，性能依赖于图的质量<sup>[18]</sup>。为此算法引入知识增强模块，通过评估三元组的相关性得分，筛选出知识图谱  $\mathcal{G}_k$  和用户项目交互图  $\mathcal{G}_u$  中的高质量信息，构造增强的知识视图和用户项目交互视图，降低噪声干扰。

传统算法中存在信息利用不平衡和高阶信号相关度低的问题，算法设计了多层次对比学习模块。采用自监督掩码重建范式和预训练编码器重建高相关三元组，强化深层信息的提取，减少对噪声信号的关注。通过图内外交互对比学习，实现信号协同利用，确保全局关键信息的捕获，有效平衡信息的使用，避免多跳传播引发的语义弱化问题。

算法设计多任务训练模块，联合训练推荐预测任务、多层次对比学习任务以及掩码重建任务，协同优化整个模型。

综上，多层次图间对比增强的知识感知传播推荐算法由知识增强、多层次信号对比学习及多任务训练 3 个模块构成。

### 2.2 知识增强模块

知识图谱中的噪声和弱相关关系降低了推荐模型的性能，尤其是在融合用户偏好与项目特征的场景中<sup>[19]</sup>。知识增强模块计算知识图谱中三元组的局部与全局相关性得分，通过排序全局得分并筛选潜在噪声三元组和弱相关交互，构造增强的知识视图  $\mathcal{G}_k^c$  与用户项目交互视图  $\mathcal{G}_u^c$ ，降低噪音干扰。

#### (1) 计算局部相关性得分

为了能从复杂知识图谱中提取用于推荐的关键语义，该模块计算局部相关性得分，其能够学习知识三元组成为协同交互潜在依据的概率。这一局部相关性得分基于一个可学习的图注意力机制，为每个知识三元组进行权重分配，局部相关性得分的计算如式(1)所示。在知识图谱  $\mathcal{G}_k$  中，三元组  $(h, r, t)$  的局部相关性得分  $f$  反映了该三元组与头实体  $h$  的相关程度，计算过程如图 1 所示。

$$f(h, r, t) = \frac{e_h W_Q \cdot (e_t W_K \odot e_r)^T}{\sqrt{d}} \quad (1)$$

其中， $e_h$ 、 $e_r$  和  $e_t$  分别是头实体、关系和尾实体的嵌入表示； $W_Q$  和  $W_K$  是可学习权重矩阵， $W_Q, W_K \in \mathbb{R}^{d \times d}$ ， $d$  为隐藏维数。

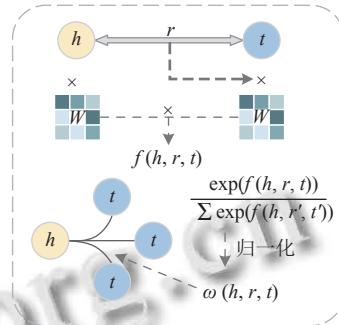


图 1 局部相关性得分计算原理图

为了保证头实体一阶邻域节点的相关性得分具有可比性，对局部相关性得分进行归一化处理，如式(2)所示：

$$\omega(h, r, t) = \frac{\exp(f(h, r, t))}{\sum_{(h, r', t') \in N_h} \exp(f(h, r', t'))} \quad (2)$$

其中， $N_h$  是头实体节点  $h$  的一阶邻域子图。

#### (2) 计算全局相关性得分

局部相关性得分仅在头实体的一阶邻域范围内具有可比性，为衡量三元组的全局重要性，算法将局部相关性得分与知识图谱中以  $e_h$  为头实体的三元组数量相乘，得到全局相关性得分。全局相关性得分计算如式(3)所示：

$$\gamma(h, r, t) = |N_h| \cdot \omega(h, r, t) = \frac{|N_h| \cdot \exp(f(h, r, t))}{\sum_{(h, r', t') \in N_h} \exp(f(h, r', t'))} \quad (3)$$

其中， $N_h$  是头实体节点  $h$  的一阶邻域子图； $|N_h|$  代表头实体节点  $h$  的相邻实体数量。

#### (3) 构造知识图谱增强视图

对所有三元组的全局相关性得分进行排序，取低分三元组构造弱相关边集  $\mathcal{S}_k$ ，从知识图谱  $\mathcal{G}_k$  中删除  $\mathcal{S}_k$ ，得到增强的知识图谱  $\mathcal{G}_k^c$ 。 $\mathcal{S}_k$  与  $\mathcal{G}_k^c$  定义如式(4)、式(5)所示：

$$\mathcal{S}_k = \{(h, r, t) | \gamma(h, r, t) \in \text{topk}(-\Gamma; \rho_m)\} \quad (4)$$

$$\mathcal{G}_k^c = \mathcal{G}_k \setminus \mathcal{S}_k \quad (5)$$

其中， $\gamma(h, r, t)$  为三元组全局相关性得分； $\Gamma$  表示所有  $\gamma(h, r, t)$  的分布。

#### (4) 构造用户项目交互图的增强视图

用户项目交互图  $\mathcal{G}_u$  定义用户-项目交互矩阵  $Y \in \mathbb{R}^{|U| \times |I|}$ , 在矩阵  $Y$  中,  $y_{u,i} = 1$  表示用户  $u$  对项目  $i$  有历史隐式反馈, 否则  $y_{u,i} = 0$ . 算法过滤用户项目交互图  $\mathcal{G}_u$  中的低相关交互, 构造增强的用户项目交互视图  $\mathcal{G}_u^c$ . 对于项目  $v$ , 计算对应实体节点相关联所有三元组  $(h, r, t)$  的全局相关性得分平均值, 得到相关性得分  $\phi_v$ , 如式(6)所示:

$$\phi_v = \text{mean}(\{\gamma(h, r, t) \mid h = v \vee t = v\}) \quad (6)$$

为防止过拟合, 采用多项分布抽样策略<sup>[20]</sup>对归一化的得分  $\phi'_v$  进行随机抽样, 获取噪声交互集合  $\mathcal{S}_u$ , 计算过程如式(7)、式(8)所示. 从用户项目交互图中减去噪声交互集合  $\mathcal{S}_u$ , 得到增强的用户项目交互图  $\mathcal{G}_u^c$ , 如式(9)所示:

$$\phi'_v = \frac{\exp(\phi_v)}{\sum_v \exp(\phi_v)} \quad (7)$$

$$\mathcal{S}_u \sim \text{multinomialNR}(\Phi'; \rho_u) \quad (8)$$

$$\mathcal{G}_u^c = \mathcal{G}_u \setminus \mathcal{S}_u \quad (9)$$

其中,  $\rho_u$  表示抽样候选样本的大小.

### 2.3 多层次对比学习模块

#### (1) 构建局部图和非局部图

传统图神经网络推荐模型融合邻近节点信息, 忽视了全局相似节点的价值. 为此, 算法构建局部与非局部图结构, 以捕获更丰富的信息.

首先, 算法通过协同处理知识信号与用户项目信号, 实现两者在知识图谱上对齐, 以此增强项目特征表示. 建立项目-实体对齐集合  $\mathcal{A} = \{(v, e) \mid v \in I, e \in E\}$ , 其中,  $I$  表示用户项目交互图  $\mathcal{G}_u$  中的项目集合,  $E$  表示知识图谱  $\mathcal{G}_k$  中的实体集,  $(v, e)$  表示项目  $v$  可以与实体  $e$  对齐.

其次, 分3步构建用户/项目局部图.

第1步, 在用户项目交互增强视图  $\mathcal{G}_u^c$  中, 获取用户/项目一阶邻域节点.

第2步, 基于项目-实体对齐集合  $\mathcal{A}$ , 按照式(10)、式(11)获取知识增强视图  $\mathcal{G}_k^c$  中对应的实体集合.

$$\mathcal{E}_{u,L}^0 = \{e \mid (v, e) \in \mathcal{A} \wedge v \in \{v \mid y_{uv} = 1\}\} \quad (10)$$

$$\mathcal{E}_{v,L}^0 = \{e \mid (v, e) \in \mathcal{A}\} \quad (11)$$

其中,  $\mathcal{E}_{u,L}^0$ 、 $\mathcal{E}_{v,L}^0$  分别表示初始用户/项目局部图中的一阶邻域实体集合.

第3步, 基于  $\mathcal{G}_k^c$  中的信号传播, 迭代获取  $L$  层内实体及三元组, 构成的知识子图作为用户/项目局部图. 第  $l$  层三元组迭代机制如式(12)所示:

$$\mathcal{S}_{o,L}^l = \{(h, r, t) \mid (h, r, t) \in \mathcal{G}_k^c \wedge h \in \mathcal{E}_{o,L}^{l-1}\}, l = 1, \dots, L \quad (12)$$

其中,  $o$  为用户  $u$  或项目  $v$ ;  $\mathcal{S}_{o,L}^l$  为第  $l$  层用户/项目局部图中包含的三元组集合.

最后, 将  $\mathcal{G}_u^c$  中高阶交互项目节点与  $\mathcal{G}_k^c$  中实体节点对齐, 构建非局部图.

第1步, 在  $\mathcal{G}_u^c$  中, 通过多阶传播获取指定用户/项目的高阶交互项目. 高阶项目定义式如式(13)–式(15)所示.

$$\mathcal{U}_{\text{sim}} = \{u_{\text{sim}} \mid v \in v \mid y_{uv} = 1 \wedge y_{u_{\text{sim}} v} = 1\} \quad (13)$$

$$\mathcal{V}_p = \{v_p \mid u \in \mathcal{U}_{\text{sim}} \wedge y_{uv_p} = 1\} \quad (14)$$

$$\mathcal{V}_u = \{v_u \mid u \in u \mid y_{uv} = 1 \wedge y_{uv_u} = 1\} \quad (15)$$

第2步, 依据式(16)和式(17), 从项目-实体对齐集合  $\mathcal{A}$  中选取与指定用户/项目高度相关的实体, 形成非局部图的初始实体集.

$$\mathcal{E}_{u,N}^0 = \{e \mid (v_p, e) \in \mathcal{A} \wedge v_p \in \mathcal{V}_p\} \quad (16)$$

$$\mathcal{E}_{v,N}^0 = \{e \mid (v_u, e) \in \mathcal{A} \wedge v_u \in \mathcal{V}_u\} \quad (17)$$

其中,  $\mathcal{E}_{u,N}^0$ 、 $\mathcal{E}_{v,N}^0$  分别指初始用户/项目非局部图中的实体集合.

第3步, 根据  $\mathcal{G}_k^c$  中的信息传播, 迭代获取  $L$  层的实体及三元组, 形成用户/项目非局部图. 迭代机制如式(18)所示:

$$\mathcal{S}_{o,N}^l = \{(h, r, t) \mid (h, r, t) \in \mathcal{G}_k^c \wedge h \in \mathcal{E}_{o,N}^{l-1}\}, l = 1, \dots, L \quad (18)$$

其中,  $\mathcal{S}_{o,N}^l$  为第  $l$  层用户/项目非局部图中的三元组集合.

#### (2) 学习对比嵌入表示

第1步, 引入知识感知的异构图神经网络<sup>[21]</sup>. 考虑到知识图谱中三元组关系的异构性<sup>[18]</sup>, 网络在聚合阶段将关系上下文  $e_r$  引入实体嵌入表示中, 并根据局部相关性得分  $\omega(h, r, t)$  赋予不同权重, 以加强关键信息捕捉. 第  $l$  层的项目嵌入表示  $e_v^{(l)}$  如式(19)所示:

$$e_v^{(l)} = e_h^{(l)} = \frac{1}{|\mathcal{N}_h|} \sum_{(h, r, t) \in \mathcal{N}_h} \omega(h, r, t) e_r \odot e_t^{(l-1)} \quad (19)$$

其中,  $v$  是  $\mathcal{G}_u^c$  中的项目节点;  $h$  是  $\mathcal{G}_u^c$  中与  $v$  对应的实体;  $l$  是聚合的层数;  $\mathcal{N}_h$  是以实体节点  $h$  为中心的一阶邻域

子图,  $\mathcal{N}_h \subseteq \mathcal{G}_k^c$ . 通过聚合  $\mathcal{G}_u^c$  中与当前用户有历史交互的所有项目的嵌入表示, 得到用户偏好嵌入表示如式(20)所示:

$$e_u^{(l)} = \frac{1}{|\mathcal{N}_u|} \sum_{v \in \mathcal{N}_u} e_v^{(l-1)} \quad (20)$$

其中,  $\mathcal{N}_u$  为用户的邻接项目集合.  $e_u$  和  $e_v$  分别表示用户嵌入和项目嵌入. 通过叠加各层次的聚合嵌入表示, 得到项目特征嵌入  $e_h$  和用户偏好嵌入  $e_u$ , 如式(21)、式(22)所示:

$$e_h = f_k(\mathcal{G}_k^c; h) = \sum_l e_h^{(l)} \quad (21)$$

$$e_u = f_u(\mathcal{G}_u^c; u) = \sum_l e_u^{(l)} \quad (22)$$

其中,  $L$  表示层数;  $f_o(\cdot, \cdot)$  是聚合计算得到实体嵌入表示的函数;  $o$  为统一占位符.

第2步, 实现编码器预训练. 生成式自监督任务能更高效地利用无标签数据, 它不需要负采样或数据增强策略<sup>[22]</sup>, 并且能让模型学到隐式信息<sup>[23,24]</sup>. 因此, 算法采自监督的掩码重建范式, 用高相关的掩码三元组作为自监督标签, 来预训练知识感知的自编码器<sup>[25]</sup>.

对  $\mathcal{G}_k^c$  中各三元组全局相关性得分排序, 得到高相关三元组集合  $\mathcal{M}_k$ , 如式(23)所示.  $\mathcal{G}_k^c$  边集中减去  $\mathcal{M}_k$  得到  $\mathcal{G}_k^m$ , 如式(24)所示. 其中,  $\Gamma$  表示所有  $\gamma(h, r, t)$  的分布.

$$\mathcal{M}_k = \{(h, r, t) | \gamma(h, r, t) \in \text{topk}(\Gamma; k_m)\} \quad (23)$$

$$\mathcal{G}_k^m = \mathcal{G}_k^c \setminus \mathcal{M}_k \quad (24)$$

在掩码知识图谱  $\mathcal{G}_k^m$  重建中, 训练得到头尾实体的嵌入表示  $e_h$ 、 $e_t$  如式(25)、式(26)所示:

$$e_h = f_k(\mathcal{G}_k^m; h) = \sum_l e_h^{(l)} \quad (25)$$

$$e_t = f_k(\mathcal{G}_k^m; t) = \sum_l e_t^{(l)} \quad (26)$$

式(27)为掩码重建的损失函数,  $\sigma(\cdot)$  表示 Sigmoid 激活函数. 自监督的掩码重建工作机制如图2.

$$L_m = \sum_{(h, r, t) \in \mathcal{M}_k} -\log \sigma(e_h^\top \cdot (e_t \odot e_r)) \quad (27)$$

第3步, 学习用户/项目嵌入表示. 基于用户/项目局部与非局部图中各层三元组集合  $\mathcal{S}_{o,L}^l$ 、 $\mathcal{S}_{o,N}^l$ , 利用编

码器学习每组三元组中尾实体的嵌入表示  $e_t$ , 并根据全局相关性得分  $\gamma(h, r, t)$  进行聚合, 获得用户/项目在第  $l$  层的嵌入表示, 计算过程如式(28)所示:

$$E_{o,D}^l = \sum_{(h, r, t) \in \mathcal{S}_{o,D}^l} \gamma(h, r, t) e_t \quad (28)$$

其中,  $\mathcal{S}_{o,D}^l$  表示局部图/非局部图中第  $l$  层的三元组集合;  $o$  为统一占位符, 若为  $u$ , 则指用户偏好表示, 若为  $v$ , 则指项目特征表示;  $D$  为统一占位符, 若为  $L$ , 则指局部视图中的特征向量, 若为  $N$ , 则指非局部视图中的特征向量.

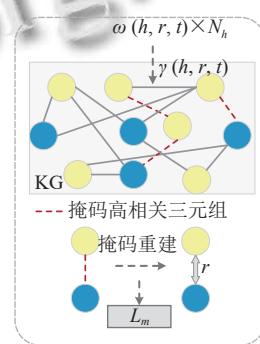


图2 自监督掩码重建机制示意图

### (3) 图内交互式对比学习

为均衡融合历史交互信号与知识信号, 算法在局部与非局部图中对用户及项目嵌入表示实施双向对比学习, 以此互相监督, 协同提取两独立部分信息.

在局部/非局部图中, 图内交互式对比学习将  $\mathcal{G}_u^c$  中获取的项目节点设定为锚点, 嵌入聚合过程中涉及  $L$  层内的知识表示作为正样本,  $L$  层之外的实体表示作为负样本, 执行对比学习. 图内交互式对比学习结构如图3所示.

根据定义的正样本和负样本, 得到用户图内交互式对比学习的损失函数  $L_{\text{Intra}}^U$  如式(29)所示:

$$L_{\text{Intra}}^U = \sum_{u \in \mathcal{U}} -\log \left( \frac{\sum_{k \in L} e^{(E_{u,L}^{(0)} \cdot E_{u,L}^{(k)} \tau)}}{\sum_{k \in L} e^{(E_{u,L}^{(0)} \cdot E_{u,L}^{(k)} \tau)} + \sum_{k' > L} e^{(E_{u,L}^{(0)} \cdot E_{u,L}^{(k')} \tau)}} \right) \\ + \sum_{u \in \mathcal{U}} -\log \left( \frac{\sum_{k \in L} e^{(E_{u,N}^{(0)} \cdot E_{u,N}^{(k)} \tau)}}{\sum_{k \in L} e^{(E_{u,N}^{(0)} \cdot E_{u,N}^{(k)} \tau)} + \sum_{k' > L} e^{(E_{u,N}^{(0)} \cdot E_{u,N}^{(k')} \tau)}} \right) \quad (29)$$

其中,  $\tau$  为  $\text{Softmax}(\cdot)$  中的一个温度参数. 由式(29)可得

项目图内交互式对比学习损失函数  $L_{\text{Intra}}^I$ , 如式(30)所示:

$$L_{\text{Intra}} = L_{\text{Intra}}^U + L_{\text{Intra}}^I \quad (30)$$

通过这种方式, 协同过滤和知识图谱能够相互监督, 进而实现一致且充分的表示学习.

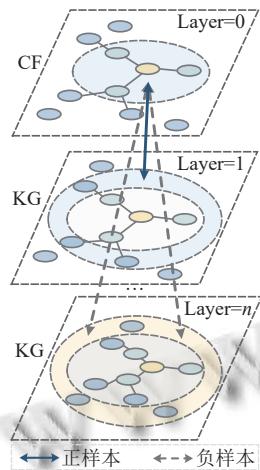


图3 图内交互式对比学习机制结构图

#### (4) 图间交互式对比学习

为了引入全局范围内的高相关信息并减少噪声影响, 采用图间交互式对比学习机制. 图间交互式对比学习机制结构图如图4所示.

根据定义的正样本和负样本, 得到用户图间交互式对比学习的损失函数  $L_{\text{Inter}}^U$  如式(31)所示:

$$L_{\text{Inter}}^U = \sum_{u \in \mathcal{U}} \sum_{k \in L} -\log \left( \frac{e^{(E_{u,L}^{(k)} \cdot E_{u,N}^{(k)})}}{e^{(E_{u,L}^{(k)} \cdot E_{u,N}^{(k)})} + \sum_{k' \neq k} e^{(E_{u,L}^{(k')} \cdot E_{u,N}^{(k')})}} \right) \quad (31)$$

由式(31)可得项目图间交互式对比学习的损失函数  $L_{\text{Inter}}^I$ , 如式(32)所示:

$$L_{\text{Inter}} = L_{\text{Inter}}^U + L_{\text{Inter}}^I \quad (32)$$

通过定义用户和物品的对比损失, 来平衡和优化模型的表示学习, 从而提高推荐系统的性能.

综上, 多层次对比学习涵盖图内交互式对比学习与图间交互式对比学习两个部分. 多层次对比学习机制的损失函数为图内对比学习损失函数  $L_{\text{Intra}}$  和图间交互式对比学习损失函数  $L_{\text{Inter}}$  的加权和, 如图5所示.

凭借这种多层次对比学习机制, 模型能够有效地

利用协同过滤和知识图谱信息, 从而进一步提升用户和物品的表示学习效果.

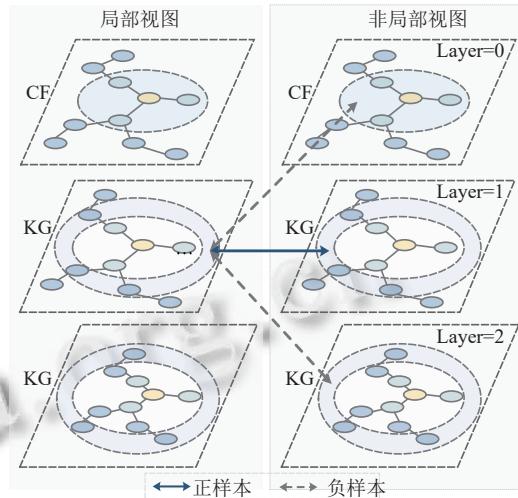


图4 图间交互式对比学习机制结构图

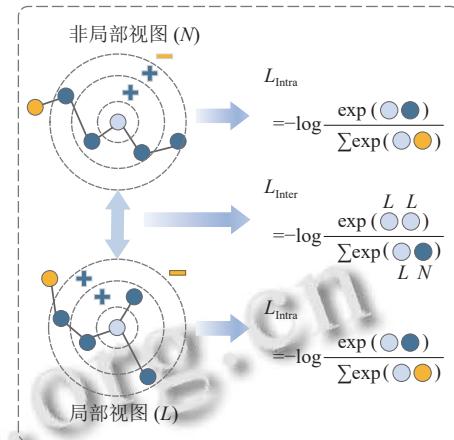


图5 多层次对比学习机制结构图

#### 2.4 多任务训练模块

##### (1) 推荐预测

经过多层次的对比学习, 优化了用户和项目在各层的嵌入表示. 不同层次的嵌入反映了用户和项目的不同特征, 通过将每一层的局部和非局部表示向量拼接, 得到最终的用户嵌入  $e_u$  和项目嵌入  $e_v$ . 如式(33)、式(34)所示:

$$e_u = [E_{u,L}^{(0)}; \dots; E_{u,L}^{(L)}; E_{u,N}^{(0)}; \dots; E_{u,N}^{(L)}] \quad (33)$$

$$e_v = [E_{v,L}^{(0)}; \dots; E_{v,L}^{(L)}; E_{v,N}^{(0)}; \dots; E_{v,N}^{(L)}] \quad (34)$$

计算用户项目嵌入表示内积, 如式(35)所示:

$$\hat{y}(u, v) = e_u^T e_v \quad (35)$$

推荐任务训练采用成对的BPR损失函数<sup>[26]</sup>,使得用户对历史交互项目的预测得分高于未交互的项目,损失函数如式(36)所示:

$$L_{\text{BPR}} = \sum_{(u,i,j) \in O} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (36)$$

其中,  $O = \{(u,i,j) | (u,i) \in O^+, (u,j) \in O^-\}$  是由已交互边  $O^+ = \{(u,i) | y_{u,i} = 1\}$  和未观察到的交互边  $O^- = \{(u,j) | y_{u,j} = 0\}$  组成的训练数据集;  $\sigma$  代表 Sigmoid 函数.

### (2) 多任务训练

为增强推荐预测、掩码重建及对比学习自监督任务的效果,模型采用多任务训练策略,将推荐任务与自监督任务结合起来,通过联合训练知识图谱感知的推荐损失和对比损失来提高模型的表现. 总体损失函数如式(37)所示:

$$L = L_{\text{BPR}} + \lambda_1 (\alpha L_{\text{Intra}} + L_{\text{Inter}}) + \lambda_2 L_m + \lambda_3 \|\Theta\|_2^2 \quad (37)$$

其中,  $\Theta$  为模型参数集;  $\lambda_1$  表示对比损失权重的超参数;  $\lambda_2$  是控制自编码器掩码重建学习任务的超参数;  $\lambda_3$  是控制  $L_2$  正则化项的超参数;  $\alpha$  为平衡图内和图间对比损失权值的超参数.

## 3 实验分析

为验证 MCLK-KE 算法效果,我们在 MovieLens-1M<sup>[27]</sup>、Last.FM<sup>[28]</sup>、Book-Crossing<sup>[29]</sup>上进行了对比实验. 通过消融实验评估关键模块对整体性能的贡献,并执行超参数实验分析指定参数对算法性能的影响.

### 3.1 实验环境与参数设置

本节实验在 64 位 Windows 10 系统上的 Anaconda 环境中运行,采用 PyTorch 1.8 和 Python 3.9 实现 NNER-SG 及所有基准实验,环境配置见表 1.

表 1 实验环境

配置	参数
系统环境	Windows 10
编程语言	Python 3.9
PyTorch 版本	PyTorch 1.8
Anaconda 版本	Anaconda 4.9.2
CUDA 版本	CUDA 10.0
TensorFlow 版本	TensorFlow 1.8

模型参数采用 Xavier 初始化,并以 Adam 优化器进行优化. 在 MCLK-KE 算法中,局部与非局部图中的三元组集规模分别限定为 40 和 128. 对比实验中各个模型的部分训练参数设置如表 2 所示.

表 2 对比实验部分训练参数设置

参数类型	MovieLens-1M	Last.FM	Book-Crossing
嵌入向量维度 $d$	64	64	64
网络层数 $L$	2	2	1
对比学习权重 $\lambda_1$	$1 \times 10^{-6}$	$1 \times 10^{-6}$	$1 \times 10^{-7}$
掩码重建权重 $\lambda_2$	$1 \times 10^{-6}$	$1 \times 10^{-6}$	$1 \times 10^{-6}$
正则化权重 $\lambda_3$	$1 \times 10^{-4}$	$1 \times 10^{-4}$	$1 \times 10^{-5}$
迭代次数	200	200	200
掩码数量	256	256	256
批处理大小	2048	2048	2048

### 3.2 数据集与评价指标

为验证算法的有效性,选取了涵盖电影(MovieLens-1M)、音乐(Last.FM)及图书(Book-Crossing)这 3 大领域的公开数据集进行实证分析. 这些数据集规模各异,稀疏程度不一,充分展现了推荐系统跨领域的适用性. 实验中,统一划分所有数据集比例,即 70% 用于训练,10% 作验证,余下 20% 为测试集,具体数据统计见表 3.

表 3 数据集统计信息

数据类型	MovieLens-1M	Last.FM	Book-Crossing
交互图	用户数	6 036	1 872
	项目数	2 445	3 846
	交互信号数	753 772	42 346
	稀疏性 (%)	94.89	99.41
知识图谱	实体数	182 011	9 366
	关系数量	12	60
	三元组数	1 241 996	15 518
		77 903	151 500

在实验中,我们对数据执行如下预处理.

(1) 在 3 个数据集中,我们将显式反馈转化为隐式反馈. 借鉴 RippleNet 算法<sup>[30]</sup>的方法,以 1 标记正样本,同时为每位用户随机选取与正样本等量的未交互项目作为负样本.

(2) 构建子知识图谱. 借鉴 RippleNet 和 KGCN 模型<sup>[31]</sup>的方法,采用微软的 Satori4 平台处理各数据集. 子知识图谱仅保留置信度大于 0.9 的三元组. 有效的电影、音乐或书籍名称与三元组尾实体对齐,提取相应项目 ID. 并将项目 ID 与三元组头实体匹配.

为全面评估推荐算法,我们在点击率预测与 Top- $K$  推荐两大场景下开展实验. 点击率预测中,以 AUC 值和 F1 值衡量算法性能. AUC 值接近 1 表明模型准确性高,而 F1 值则平衡了准确率与召回率,反映算法的整体效能. 在 Top- $K$  推荐场景,通过 Recall@ $K$  ( $K$  取值为 {5, 10, 20, 50, 100}) 评估算法表现,考察不同情境下推荐系统的精准度.

### 3.3 对比实验

#### (1) 基线实验

为验证 MCLK-KE 模型的有效性, 我们选取了一系列基线算法进行对比实验, 包括: 协同过滤模型 (BPRMF<sup>[14]</sup>)、知识感知推荐算法中嵌入法 (RippleNet<sup>[30]</sup>)、基于路径的方法 (PER<sup>[32]</sup>) 和图神经网络 KGCN<sup>[31]</sup>、KGAT<sup>[10]</sup>、KGIN<sup>[11]</sup>、CG-KGR<sup>[33]</sup> 以及自监督的模型 MCCLK<sup>[25]</sup>。以下是对各基线算法的描述。

BPRMF: 结合了贝叶斯个性化排名和因子分解机, 通过矩阵分解学习用户和项目的潜在表示, 提高推荐准确度。

RippleNet: 通过迭代利用知识图谱中的链接传播用户偏好, 以此拓展用户的潜在兴趣范围。

PER: 利用元路径特征描绘用户与项目间的关联路径。

KGCN: 通过迭代聚合节点间的高阶邻域信息, 项目的特征表示得以增强。

KGAT: 集成注意力网络, 通过量化实体与关系的重要程度, 为图中的邻域结构和语义信息赋予权重, 进而聚合形成用户和项目的嵌入表示。

KGIN: 模型针对用户意图建模, 设计了信息聚合机制, 应用于用户-意图-项目及知识三元组上。

CG-KGR: 模型使用 GNN 将协作信号融合为知识聚合。

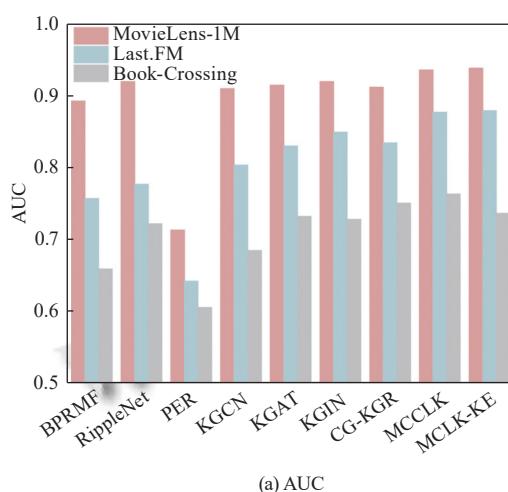
MCCLK: 模型利用基于局部语义视图和全局语义视图的多层次对比学习机制来学习更丰富的特征信息。

#### (2) 实验结果与分析

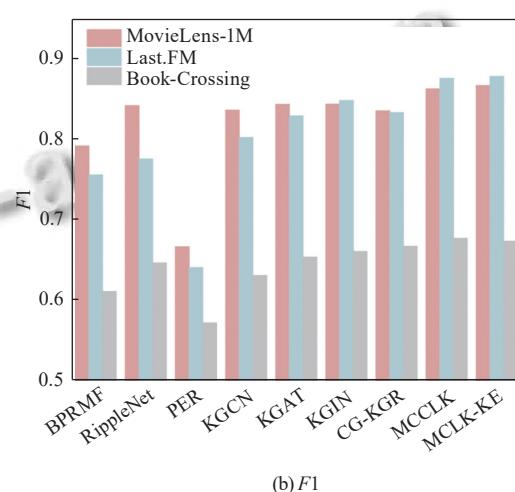
表 4、图 6 和图 7 展示了点击率预测和 Top-K 推荐两种实验场景下, MCLK-KE 与多种基线模型性能对比结果。MCLK-KE 在 3 个不同数据集上 AUC、F1 和 Recall@K 指标上均优于大部分基线模型, 表现出优异的性能。在 Top-K 推荐场景中, 随着 K 值增加 Recall@K 指标也随之上升。这是因为 K 值增加意味着推荐列表容纳更多项目, 从而提高了命中目标项目的机会, 直接推动 Recall 值的提升。

表 4 点击率预测场景下各模型实验结果对比结果

Model	MovieLens-1M		Last.FM		Book-Crossing	
	AUC	F1	AUC	F1	AUC	F1
BPRMF	0.8920	0.7921	0.7563	0.7010	0.6583	0.6117
RippleNet	0.9190	0.8422	0.7762	0.7025	0.7211	0.6472
PER	0.7124	0.6670	0.6414	0.6033	0.6048	0.5726
KGCN	0.9091	0.8366	0.8027	0.7086	0.6840	0.6314
KGAT	0.9140	0.8440	0.8294	0.7425	0.7314	0.6544
KGIN	0.9190	0.8441	0.8486	0.7602	0.7273	0.6614
CG-KGR	0.9110	0.8359	0.8336	0.7433	0.7498	0.6678
MCCLK	0.9351	0.8631	0.8763	0.8008	0.7625	0.6777
MCLK-KE	0.9377	0.8672	0.8786	0.8005	0.7358	0.6740



(a) AUC



(b) F1

图 6 各模型在 3 个数据集中的 AUC 值和 F1 值对比

在点击率预测任务中, MCLK-KE 相较于基于图神经网络的推荐模型如 KGCN、KGAT、KGIN、CG-KGR, 在各指标上均有提升。具体而言, 相较于 KGIN 和 CG-KGR 在 MovieLens-1M 和 Last.FM 两个数据集上, MCLK-KE 使 AUC 指标分别提高了 2.0% 和 3.3%,

F1 指标在 MovieLens-1M、Last.FM、Book-Crossing 这 3 个数据集上分别提升了 2.7%、5.3% 和 0.7%。这是因为基于 GNN 的模型虽然能学习丰富信息, 但也引入了噪声, 影响了模型效果。而 MCLK-KE 通过知识增强过滤噪声信息, 关注高相关信号, 改善了推荐性能。

MCLK-KE 还通过掩码重建的预训练机制, 增强对重要信息的关注, 抑制噪声影响, 并利用多层次对比学习平

衡交互信号和知识信号, 生成更强的节点表示, 提升了推荐算法性能.

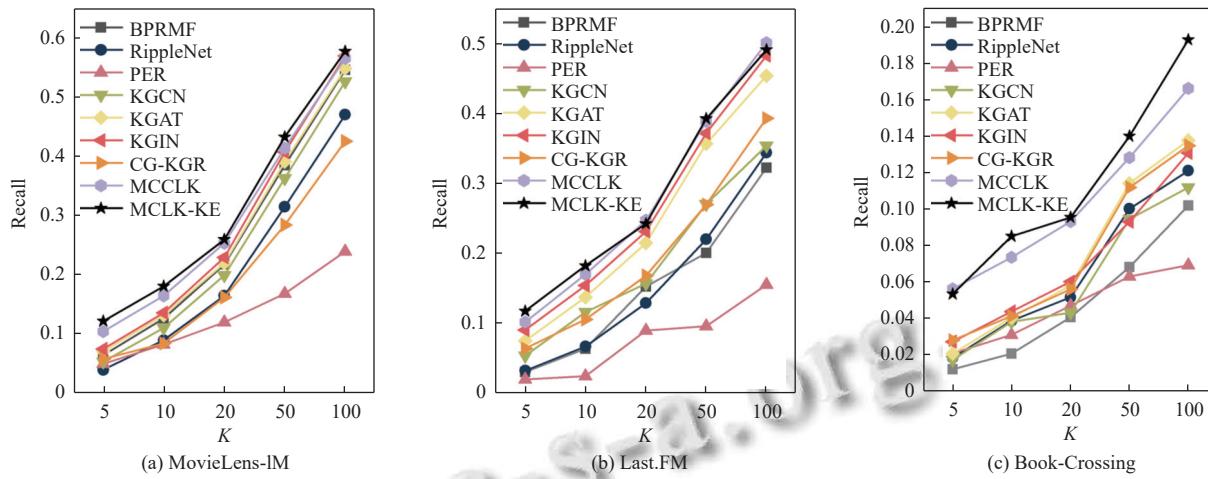


图 7 各模型在 3 个数据集中的 Recall@K 值对比

相较于传统协同过滤模型 BPRMF, MCLK-KE 及多数知识感知推荐模型在各项指标上表现出色, 这归功于它们利用知识图谱, 为用户和项目引入丰富的辅助信息, 通过挖掘知识图谱中的深层次关联, 有效缓解信号稀疏与冷启动问题, 提升了推荐性能. 然而, 基于路径的 PER 模型却未见提升, 甚至逊于 BPRMF, 原因在于现实世界中难以界定用户最优元路径.

通过对数据集特性的分析, 我们发现 MCLK-KE 在 Book-Crossing 数据集上表现略逊于最佳基线模型, 主要归因于该数据集信息质量较高, 直接聚合所有信息反而更利于性能提升, 且在稀疏数据集上不会显著增加计算负担. 而在数据更为密集的 MovieLens-1M 和 Last.FM 数据集上, MCLK-KE 的知识增强机制能够精挑细选邻居节点信息, 有效剔除无关噪声, 因此展现出更显著的性能优势.

### 3.4 消融实验

通过消融实验, 对比了 MCLK-KE 及其 3 个关键组件变体在各数据集上的 AUC 和 F1 指标, 以量化这些组件对整体性能的具体贡献.

#### (1) 算法变体

**MCLK-KE w/o MEA:** 算法变体禁用基于掩码重构得到的知识感知编码器.

**MCLK-KE w/o Intra:** 算法变体在对比学习阶段禁用图内交互式对比学习模块, 仅保留并执行局部图与非局部图之间的图间交互式对比学习过程.

**MCLK-KE w/o Inter:** 算法变体禁用图间交互式对

比学习模块, 对比学习过程仅限于局部图和非局部图内部的交互学习, 不再进行跨图对比.

#### (2) 实验结果与分析

图 8 展示了 MCLK-KE 与其变体的实验结果, 分析如下: MCLK-KE 的 3 个变体 (MCLK-KE w/o MEA、w/o Intra、w/o Inter) 在各项指标上均有下降, 表明掩码自编码器预训练、图内对比学习及图间对比学习模块对性能提升都有贡献. 其中, MCLK-KE w/o MEA 表现最差, 说明知识感知掩码自编码器在增强实体表示中的核心作用, 尤其是在筛选有效信息和抑制噪声方面. 多层次对比学习的缺失导致算法变体性能下滑, 验证了该模块在缓解稀疏性问题和增强用户/项目表示上的有效性. 此外, MCLK-KE w/o Intra 与 MCLK-KE w/o Inter 的对比显示, 图间对比学习更有利子性能提升, 表明了跨图交互的重要性.

### 3.5 超参实验

通过超参数实验, 研究网络层数  $L$  与图内交互式对比学习权重  $\alpha$  对算法性能的影响, 并确定了它们的最优设置.

网络层数  $L$ , 即局部/非局部图中的聚合层数, 对算法效果至关重要. 在 {1, 2, 3} 的范围内取  $L$  的值, 实验结果如表 5 所示. 分析结果可知, 在 MovieLens-1M、Last.FM 和 Book-Crossing 数据集上,  $L$  分别取值为 2、2、1 时, 算法表现最优. 这表明,  $L$  值过小或过大都会降低算法性能. 聚合层太少无法充分挖掘高阶信息, 而过多的聚合层又会引入过多的噪声, 两者都不利于提

升推荐效果。

图内交互式对比权重  $\alpha$  的影响。对  $\alpha$  取 {0.1, 0.5, 1, 1.5, 2} 进行实验, 结果如图 9、图 10 所示。结果表明:  $\alpha$  值会对算法性能产生影响。尤其  $\alpha=1$  时, 图内外对比

学习等重, 算法表现最优, 说明图内和图间对比学习具有同等的重要性。同时, 无论  $\alpha$  如何变化, MCLK-KE 始终优于其他基线, 证实了采用多层次交互式对比学习机制的有效性。

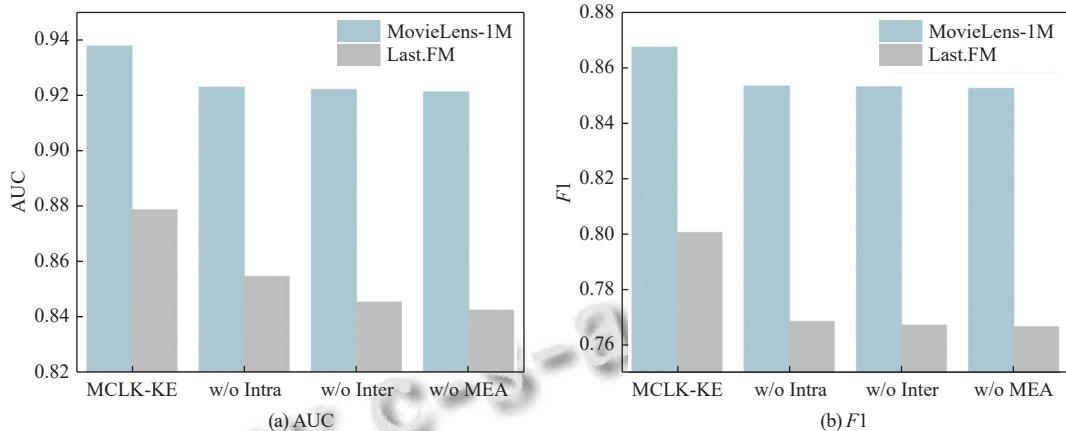


图 8 各算法变体的 AUC 值和 F1 值对比

表 5 L 取不同值时结果对比结果

L	MovieLens-1M		Last.FM		Book-Crossing	
	AUC	F1	AUC	F1	AUC	F1
1	0.9241	0.8551	0.8482	0.789	0.7358	0.6740
2	0.9377	0.8672	0.8786	0.8005	0.7319	0.6705
3	0.9203	0.8521	0.8511	0.7794	0.7313	0.6718

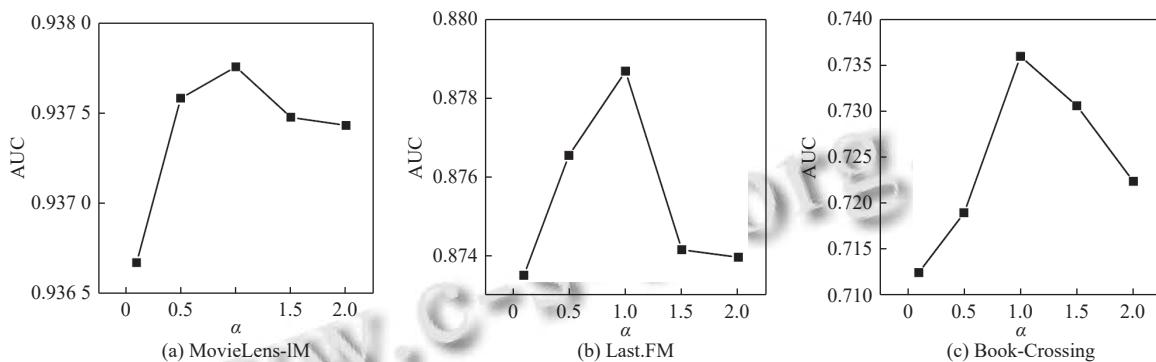


图 9  $\alpha$  取不同值时 3 个数据集中 AUC 值对比

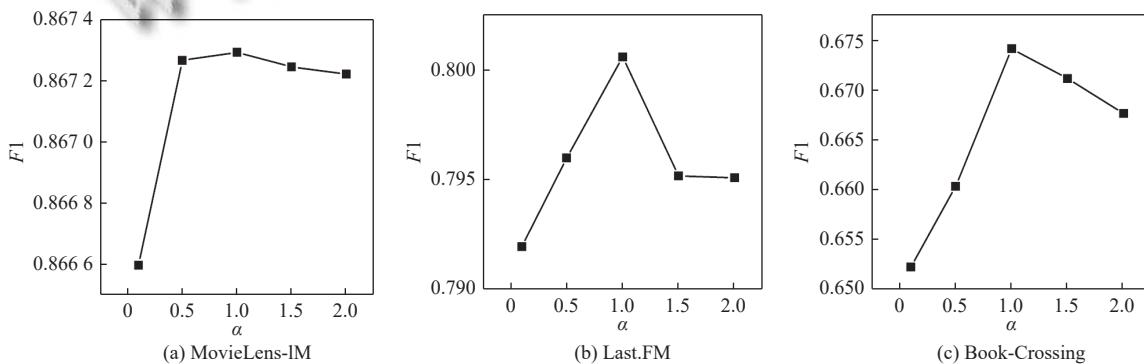


图 10  $\alpha$  取不同值时 3 个数据集中 F1 值对比

## 4 结论与展望

针对传统的基于对比学习的知识感知传播推荐算法中存在的高阶特征相关度低、信息利用不平衡以及噪声引入等问题,本文提出了多层次图间对比增强的知识感知传播推荐算法(MCLK-KE),此算法由知识增强、多层次对比学习和多任务训练这3个模块组成。

算法通过滤除协同信号和知识信号中的噪声信息,构建增强的知识视图和用户项目交互视图,进而减少了后续建模过程中的噪声引入。引入多层次对比学习机制,借助图内交互式对比学习实现对冗余的知识信号和稀疏的交互信号的平衡利用,依靠图间交互式对比学习捕获全局范围内的高相关信息,增强了高阶特征的有效建模能力。采用多任务学习策略,实现了推荐预测任务、对比学习任务以及掩码重建任务的联合训练,优化了模型性能。

实验结果显示,与KGIN和CG-KGR这两个基准模型相比,MCLK-KE在MovieLens-1M、Last.FM两个数据集上,AUC指标提升了2.0%、3.3%;在MovieLens-1M、Last.FM、Book-Crossing这3个数据集上,F1指标分别提升了2.7%、5.3%和0.7%,充分验证了MCLK-KE在提升推荐算法性能方面的有效性。

当前知识感知推荐算法依赖静态知识图谱,无法反映实体属性及关系随时间的变化,因此难以适应实时性需求高的场景。下一步考虑利用时态知识图谱与时间图注意力网络技术,依据用户的即时反馈动态调整推荐,以此优化用户体验。

## 参考文献

- 1 Zou D, Wei W, Mao XL, et al. Multi-level cross-view contrastive learning for knowledge-aware recommender system. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 1358–1368.
- 2 鄢凡力,胥小波,赵容梅,等.基于跨视图对比学习的知识感知推荐系统.工程科学与技术,2024,56(1): 44–53.
- 3 张波,赵鹏,张金金,等.基于用户潜在兴趣的知识感知传播推荐算法.计算机应用研究,2022,39(9): 2615–2620.
- 4 Zou D, Wei W, Wang ZY, et al. Improving knowledge-aware recommendation with multi-level interactive contrastive learning. Proceedings of the 31st ACM International Conference on Information & Knowledge Management. Atlanta: ACM, 2022. 2817–2826.
- 5 Liu WJ, Zhou P, Zhao Z, et al. K-Bert: Enabling language representation with knowledge graph. Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York: AAAI, 2020. 2901–2908.
- 6 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.
- 7 Wang HW, Zhang FZ, Zhao M, et al. Multi-task feature learning for knowledge graph enhanced recommendation. Proceedings of the 2019 World Wide Web Conference. San Francisco: ACM, 2019. 2000–2010.
- 8 Chen HX, Li YC, Sun XG, et al. Temporal meta-path guided explainable recommendation. Proceedings of the 14th ACM International Conference on Web Search and Data Mining. ACM, 2021. 1056–1064.
- 9 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.
- 10 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.
- 11 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.
- 12 Qiu JZ, Chen QB, Dong YX, et al. GCC: Graph contrastive coding for graph neural network pre-training. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. California: ACM, 2020. 1150–1160.
- 13 Hassani K, Khasahmadi AH. Contrastive multi-view representation learning on graphs. Proceedings of the 37th International Conference on Machine Learning. PMLR, 2020. 4116–4126.
- 14 Hu ZN, Dong YX, Wang KS, et al. GPT-GNN: Generative pre-training of graph neural networks. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. California: ACM, 2020. 1857–1867.
- 15 Pan SR, Hu RQ, Long GD, et al. Adversarially regularized graph autoencoder for graph embedding. Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm: ijcai.org, 2018. 2609–2615.

- 16 You YN, Chen TL, Shen Y, et al. Graph contrastive learning automated. Proceedings of the 38th International Conference on Machine Learning. PMLR, 2021. 12121–12132.
- 17 Sun QY, Li JX, Peng H, et al. SUGAR: Subgraph neural network with reinforcement pooling and self-supervised mutual information mechanism. Proceedings of the 2021 Web Conference. Ljubljana: ACM, 2021. 2081–2091.
- 18 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.
- 19 Tian Y, Yang YH, Ren XH, 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. ACM, 2021. 51–60.
- 20 Huang TS, Lin WW, Shen L, et al. Stochastic client selection for federated learning with volatile clients. IEEE Internet of Things Journal, 2022, 9(20): 20055–20070. [doi: [10.1109/JIOT.2022.3172113](https://doi.org/10.1109/JIOT.2022.3172113)]
- 21 Li T, Sahu AK, Zaheer M, et al. Federated optimization in heterogeneous networks. Proceedings of the 3rd Conference on Machine Learning and Systems. Austin: mlsys.org, 2020. 429–450.
- 22 Xiao ST, Liu Z, Shao YX, et al. RetroMAE: Pre-training retrieval-oriented language models via masked auto-encoder. Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi: Association for Computational Linguistics, 2022. 538–548.
- 23 Feichtenhofer C, Fan HQ, Li YH, et al. Masked autoencoders as spatiotemporal learners. Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2024. 2605.
- 24 富坤, 郝玉涵, 孙明磊, 等. 基于优化图结构自编码器的网  
络表示学习. 计算机应用, 2023, 43(10): 3054–3061.
- 25 Xia LH, Huang C, Huang CZ, et al. Automated self-supervised learning for recommendation. Proceedings of the 2023 ACM Web Conference. Austin: ACM, 2023. 992–1002.
- 26 郭洁, 林佳瑜, 梁祖红, 等. 基于知识感知和跨层次对比学习的推荐方法. 计算机应用, 2024, 44(4): 1121–1127.
- 27 Harper FM, Konstan JA. The MovieLens datasets: History and context. ACM Transactions on Interactive Intelligent Systems, 2015, 5(4): 19.
- 28 Schedl M. The LFM-1b dataset for music retrieval and recommendation. Proceedings of the 2016 ACM on International Conference on Multimedia Retrieval. New York: ACM, 2016. 103–110.
- 29 Ziegler CN, McNee SM, Konstan JA, et al. Improving recommendation lists through topic diversification. Proceedings of the 14th International Conference on World Wide Web. Chiba: ACM, 2005. 22–32.
- 30 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.
- 31 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.
- 32 黄偲偲, 柯文俊, 张杭, 等. 融合知识传播和提示学习机制的推荐模型. 中文信息学报, 2023, 37(5): 122–134.
- 33 Chen YK, Yang YM, Wang YJ, et al. Attentive knowledge-aware graph convolutional networks with collaborative guidance for personalized recommendation. Proceedings of the 38th IEEE International Conference on Data Engineering. Kuala Lumpur: IEEE, 2022. 299–311.

(校对责编: 张重毅)