

知识图谱与大语言模型的语义增强推荐方法

顾凯, 苗秀琪, 陆明航

上海理工大学光电信息与计算机工程学院, 上海

收稿日期: 2026年3月21日; 录用日期: 2026年4月14日; 发布日期: 2026年4月23日

摘要

针对传统知识图谱推荐方法在异构知识融合困难、局部语义挖掘不足和复杂关联关系建模能力有限等问题, 提出一种知识图谱与大语言模型的语义增强推荐方法LLM-KGRec。首先, 利用大语言模型对多源异构知识图谱进行语义标准化, 统一实体表达与关系表示。其次, 围绕候选物品构建局部知识子图, 并借助大语言模型挖掘局部知识的深层语义信息。进一步, 引入全局跨源语义检索机制, 补充候选物品的外部语义上下文。最后, 融合交互特征、知识图谱结构特征与多粒度语义特征, 实现推荐预测。实验表明, 所提方法在多个公开数据集上的NDCG@10, Recall@10等指标均优于对比模型, 在数据稀疏和复杂语义场景下表现出较好的鲁棒性与泛化能力。

关键词

推荐系统, 知识图谱, 大语言模型, 语义增强, 特征融合

A Semantic-Enhanced Recommendation Method Integrating Knowledge Graphs and Large Language Models

Kai Gu, Xiuqi Miao, Minghang Lu

School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai

Received: March 21, 2026; accepted: April 14, 2026; published: April 23, 2026

Abstract

To address the limitations of traditional knowledge graph-based recommendation methods in heterogeneous knowledge fusion, local semantic mining, and complex relational modeling, a semantic-enhanced recommendation method integrating knowledge graphs and large language models, named

LLM-KGRec, is proposed. First, a large language model is employed to perform semantic standardization on multi-source heterogeneous knowledge graphs, so as to unify entity expressions and relation representations. Second, local knowledge subgraphs are constructed around candidate items, and the large language model is used to capture the deep semantic information embedded in local structures. Furthermore, a global cross-source semantic retrieval mechanism is introduced to supplement external semantic context for candidate items. Finally, interaction features, structural features of the knowledge graph, and multi-granularity semantic features are fused to achieve recommendation prediction. Experimental results on multiple public datasets show that the proposed method outperforms baseline models in terms of NDCG@10, Recall@10, and other evaluation metrics, and demonstrates better robustness and generalization ability in sparse-data, cold-start, and complex semantic scenarios.

Keywords

Recommender System, Knowledge Graph, Large Language Model, Semantic Enhancement, Feature Fusion

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着互联网信息规模的持续增长,推荐系统已成为缓解信息过载、提升信息获取效率的重要技术,并广泛应用于电子商务、内容分发和医疗服务等领域[1]。传统推荐方法主要依赖用户-物品交互数据进行偏好建模,在数据较为充分时通常能够取得较好的推荐效果。然而,当交互数据稀疏或存在冷启动问题时,模型往往难以学习稳定有效的用户和物品表示,从而导致推荐性能下降[2]。

为增强推荐模型的语义表示能力,知识图谱推荐方法逐渐受到关注[3]。知识图谱通过实体、关系和属性三元组组织外部知识,能够为推荐系统提供丰富的结构化语义信息,从而改善用户兴趣建模和物品表示学习效果[4]。但现有知识图谱推荐方法仍存在一些不足。一方面,多源知识在实体命名、关系表达和语义粒度上存在差异,异构知识难以统一融合;另一方面,许多方法主要依赖图结构传播,对局部知识子图中蕴含的深层语义信息挖掘不足,对跨实体、跨层次复杂关联关系的建模能力也相对有限。

近年来,大语言模型在语义理解、知识归纳和上下文推理方面表现出较强能力,为推荐系统研究提供了新的思路[5]。将知识图谱的结构化表示能力与大语言模型的深层语义理解能力结合,有望进一步提升推荐系统在复杂场景下的表现。现有研究已开始尝试将大语言模型加入知识感知推荐任务,通过图增强等方式改善知识表示和推荐性能[6]。然而,对异构知识标准化、局部子图语义理解和全局知识增强的协同利用仍有进一步提升空间。

针对上述问题,本文提出一种知识图谱与大语言模型的语义增强推荐方法 LLM-KGRec。该方法首先利用大语言模型对多源异构知识图谱进行语义标准化,统一实体表达与关系表示;其次,围绕候选物品构建局部知识子图,并借助大语言模型挖掘局部知识的深层语义信息;进一步,引入全局跨源语义检索机制,补充候选物品的外部语义上下文;最后,融合交互特征、知识图谱结构特征与多粒度语义特征,实现推荐预测。本文的主要贡献包括:

1) 提出一种知识图谱与大语言模型的语义增强推荐方法 LLM-KGRec,实现异构知识标准化、局部语义理解、全局语义检索与推荐预测的统一建模。

2) 设计局部知识子图语义理解与全局跨源语义检索相结合的增强机制,提高模型对深层语义信息和复杂关联关系的刻画能力。

3) 在多个公开数据集上的实验结果表明,所提方法在 $NDCG@10$ 、 $Recall@10$ 等指标上均优于对比模型,并在数据稀疏、冷启动和复杂语义场景下表现出较好的鲁棒性与泛化能力。

2. 相关工作

2.1. 知识图谱推荐方法

知识图谱推荐方法通过引入实体、关系和属性等外部知识,为推荐系统提供结构化语义信息支持,从而增强用户兴趣建模和物品表示学习能力[3]。相较于仅依赖用户-物品交互数据的传统推荐方法,知识图谱推荐能够利用物品相关实体及其关系信息,在一定程度上缓解数据稀疏和冷启动问题,并提升推荐结果的语义表达能力。

现有知识图谱推荐方法主要包括三类:基于知识图谱嵌入的方法、基于路径建模的方法和基于图神经网络的方法。基于知识图谱嵌入的方法通常通过联合学习用户、物品与知识图谱实体的低维表示,实现推荐任务与知识表示任务的协同优化;基于路径建模的方法侧重于挖掘用户与物品之间的语义连接路径,以增强关联关系建模能力;基于图神经网络的方法则通过邻域聚合和结构传播机制,对知识图谱中的高阶连接关系进行建模,从而进一步提升知识利用效果[4]。

总体来看,知识图谱推荐方法能够有效引入外部结构化知识,改善推荐模型对用户偏好和物品语义的刻画能力。然而,现有方法大多侧重于图结构传播和邻域信息聚合,对多源异构知识的统一表示能力不足;同时,对局部知识子图中蕴含的深层语义信息挖掘仍不充分,难以有效建模跨实体、跨层次的复杂关联关系。因此,如何在利用知识图谱结构信息的基础上进一步增强语义理解能力,仍是知识图谱推荐研究中的重要问题。

2.2. 大语言模型增强推荐方法

随着大语言模型在自然语言理解、知识归纳和上下文推理等任务中的快速发展,研究者开始探索其在推荐系统中的应用[5]。相较于传统推荐模型,大语言模型具备更强的语义建模能力,能够从用户评论、物品描述和上下文信息中提取更丰富的隐式语义特征,从而为用户偏好建模和候选物品表示提供新的支持。

现有大语言模型增强推荐方法主要包括:基于文本语义建模的方法、基于提示学习的方法和生成式推荐方法。基于文本语义建模的方法通常利用大语言模型对用户历史行为文本、物品描述文本或评论信息进行编码,以增强语义表示能力;基于提示学习的方法通过构造任务提示,引导大语言模型完成偏好理解、候选重排序等任务;生成式推荐方法则进一步利用大语言模型的生成能力,实现推荐结果生成、推荐解释生成和对话式推荐等功能。已有研究表明,大语言模型能够在一定程度上提升推荐系统对复杂语义信息和上下文关系的建模能力[6]。

尽管如此,现有大语言模型增强推荐方法仍存在一定局限。多数方法更侧重于文本侧语义建模,对知识图谱中的显式结构关系利用不足;同时,在知识感知推荐场景下,如何协同利用结构化知识与深层语义信息,仍有进一步研究空间。因此,将大语言模型的语义理解能力与知识图谱的结构化表示能力相结合,成为提升推荐系统性能的重要方向。

2.3. 知识图谱与大语言模型融合推荐方法

为同时发挥知识图谱的结构化表示优势与大语言模型的深层语义理解能力,已有研究开始探索二者

的融合建模[6]。相关方法表明，大语言模型不仅可以用于文本语义编码，还能够通过知识增强等方式改善知识感知推荐效果[7]。这类方法通常从两个方面展开：一类方法利用大语言模型补充用户偏好推理信息或物品外部知识，以增强推荐模型对开放世界信息的利用能力；另一类方法则侧重于借助大语言模型优化知识表示，从而提升推荐任务中的知识利用效果。

总体来看，知识图谱与大语言模型的融合为推荐系统提供了新的研究思路。知识图谱能够提供显式、可组织的结构化知识，有助于增强推荐模型对实体关系和高阶连接的建模能力；大语言模型则具备较强的语义理解与上下文推理能力，能够弥补传统知识图谱推荐方法在深层语义表示上的不足。二者的结合有助于同时提升推荐模型的知识表达能力与语义建模能力。

尽管如此，现有融合方法仍存在一定局限。首先，对多源异构知识的语义标准化考虑不足，不同知识来源之间的实体表达和关系表示难以统一。其次，对局部知识子图的深层语义理解仍不充分，难以有效挖掘局部结构中的隐含语义信息。再次，对局部知识与全局语义上下文的协同利用仍较有限，导致模型对复杂关联关系和高阶语义依赖的刻画能力不足。因此，如何在知识图谱结构建模的基础上进一步引入大语言模型的语义理解能力，并实现局部与全局知识的统一增强，仍是当前研究中的重要问题。

3. 算法模型

3.1. 问题定义

设用户集合和物品集合分别为 $U = \{u_1, u_2, \dots, u_M\}$ 和 $V = \{v_1, v_2, \dots, v_N\}$ ，用户 - 物品交互集合记为：

$$Y = \{(u, v) | u \in U, v \in V\} \quad (1)$$

给定与物品相关联的知识图谱：

$$G = \{(h, r, t) | h, t \in E, r \in R\} \quad (2)$$

其中 E 和 R 分别表示实体集合和关系集合。

本文围绕目标用户与候选物品，综合利用三类信息进行推荐建模：知识图谱中的结构化关系信息、局部知识子图语义信息以及跨源检索得到的全局语义信息。目标是在用户 - 物品交互信息和知识图谱结构信息基础上，引入异构知识语义标准化、局部子图语义理解和全局语义增强机制，学习用户偏好函数：

$$\hat{y}_{uv} = f(u, v, G) \quad (3)$$

以预测用户对候选物品的兴趣得分，并生成 Top-N 推荐结果。

3.2. 模型总体框架

为解决知识图谱推荐中存在的语义缺失、高阶关系建模受限以及跨源知识集成一致性不足等问题，本文提出一种融合大语言模型与知识图谱的语义增强推荐框架 LLM-KGRec (Large Language Model enhanced Knowledge Graph Recommendation)。在保留知识图谱结构化建模优势的基础上，该框架引入大语言模型对实体语义、局部上下文语义以及跨源背景知识进行补充与增强，从而实现对用户偏好的更全面刻画。

LLM-KGRec 主要由四个相互协同的核心模块构成。首先，异构知识图谱语义标准化模块利用大语言模型对不同知识源中的实体和关系进行语义对齐与统一表示，以提高多源知识融合的一致性。其次，局部知识子图深层语义理解模块围绕候选物品构建局部知识子图，并借助大语言模型挖掘与用户 - 物品交互相关的深层语义信息，从而增强局部结构表示能力。进一步地，全局跨源语义检索模块从更大范围的语义空间中检索与目标物品相关的外部知识，用于补充局部结构之外的背景语义信息，提高模型对复杂

关联关系和高阶语义依赖的建模能力。最后，多源特征融合与推荐预测模块综合用户-物品交互特征、知识图谱结构特征、局部语义特征和全局语义特征，实现最终推荐预测。

模型整体流程如图 1 所示。首先，对多源异构知识图谱进行语义标准化处理，构建统一的知识表示空间，并生成标准化主题表示；然后，从标准化后的知识图谱中抽取候选物品的局部知识子图，通过局部子图语义建模获得对应的深层语义表示；在此基础上，结合局部结构表示与语义表示进行跨源检索，获得目标物品的全局语义增强表示；最后，将用户与物品的 ID 嵌入、知识图谱结构嵌入、局部语义嵌入以及全局语义嵌入进行融合，学习用户对候选物品的偏好得分，并完成推荐预测。

与传统知识图谱推荐方法相比，LLM-KGRec 不仅利用知识图谱中的显式结构关系，还通过大语言模型增强了对局部子图语义和跨源背景知识的理解能力，从而实现结构信息与语义信息的统一建模。该框架为后续的异构知识语义标准化、局部知识子图语义理解、全局跨源语义检索以及多源特征融合预测提供了整体支撑。

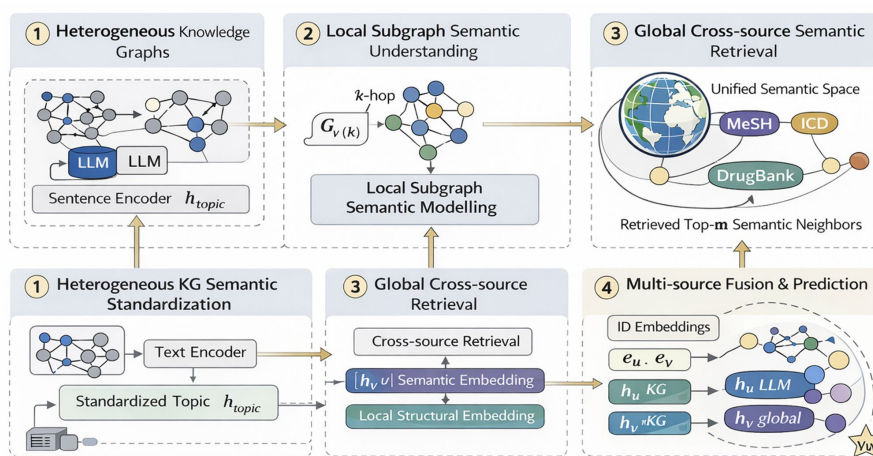


Figure 1. Overall framework diagram of the LLM-KGRec model

图 1. LLM-KGRec 模型整体框架图

3.3. 异构知识图谱语义标准化

在实际推荐场景中，知识通常来源于多个异构数据源，不同知识源在实体命名、关系表达和语义粒度上往往存在差异。若直接将多源知识图谱进行拼接，容易造成语义冲突和表示不一致问题。为此，本文首先设计异构知识图谱语义标准化模块，利用大语言模型对不同知识源中的实体与关系进行语义对齐，构建统一的知识表示空间。

设原始异构知识图谱为：

$$G = \{(h, r, t) \mid h, t \in E, r \in R\} \quad (4)$$

其中， h 、 r 、 t 分别表示头实体、关系和尾实体， E 和 R 分别表示实体集合和关系集合。对于来自不同知识源的原始三元组，本文首先将其转换为文本形式的语义描述，并输入大语言模型进行语义理解与表示映射。通过该过程，可将语义相近但表达形式不同的实体和关系对齐到统一表示空间，得到标准化后的知识图谱：

$$G' = \{(h', t', r') \mid h', t' \in E', r' \in R'\} \quad (5)$$

其整体过程如图 2 所示。首先，从不同知识源获取原始知识图谱三元组；其次，利用大语言模型和

文本编码器对实体与关系进行语义重构与统一表示；最后，生成标准化主题向量

$$h_{topic} = \text{Encoder}(G') \quad (6)$$

作为后续局部知识子图语义理解和全局跨源语义检索的基础表示。通过该模块，模型能够缓解多源知识中的语义不一致问题，提高后续知识融合与推荐建模的稳定性。

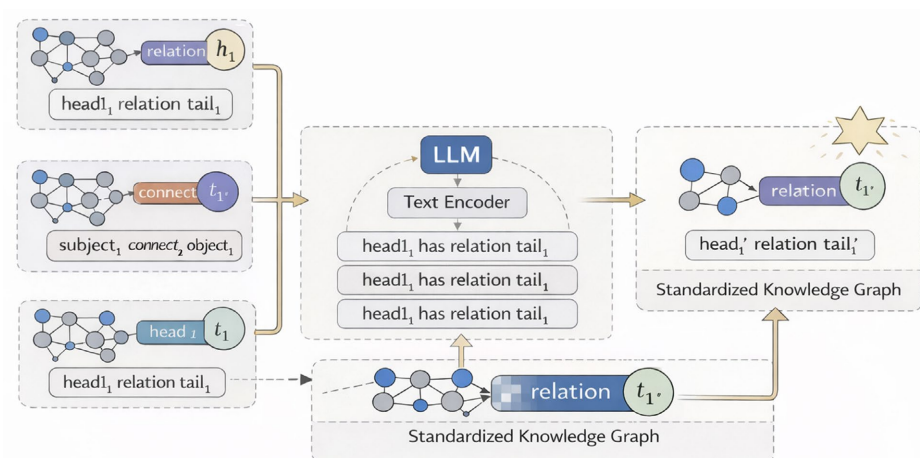


Figure 2. Schematic diagram of semantic standardization of heterogeneous knowledge graphs
图 2. 异构知识图谱语义标准化示意图

在具体实现中，本研究采用 GPT-3.5-turbo 作为核心大语言模型。为了将原始三元组 (h, r, t) 转换为高质量的语义描述，我们设计了如下提示模版(Prompt Template)：

“请将以下知识图谱三元组转换为一段自然、连贯且消除歧义的描述性短语：[头实体]的关系是[尾实体]”。

随后，利用预训练的 Sentence-BERT 作为文本编码器 $\text{Encoder}(\cdot)$ ，提取该描述的[CLS]位向量作为标准化主题表示 h_{topic} 。这一过程确保了来自不同源的同义实体(如“Titanic”与“泰坦尼克号”)能够在统一的向量空间中完成对齐。

3.4. 局部知识子图深层语义理解

在完成异构知识图谱语义标准化后，模型进一步围绕候选物品构建局部知识子图，以提取与用户-物品交互相关的邻域语义信息。相较于仅依赖图结构传播的传统方法，局部知识子图不仅包含实体之间的显式连接关系，还蕴含属性组合、语义主题和局部上下文等深层信息。因此，本文引入大语言模型对局部知识子图进行语义建模，以增强物品表示的语义表达能力。

设候选物品 v 的 K -hop 局部知识子图记为

$$G_v^{(k)} = \{(h, r, t) \mid h, t \in E_v^{(k)}, r \in R_v^{(k)}\} \quad (7)$$

其中， $E_v^{(k)}$ 和 $R_v^{(k)}$ 分别表示局部子图中的实体集合和关系集合。本文首先围绕候选物品抽取其 K -hop 邻域结构，再将局部子图序列化为语义描述，并输入大语言模型进行语义编码，从而获得候选物品的局部语义表示：

$$h_v^{local} = \text{LLM}(G_v^{(k)}) \quad (8)$$

局部知识子图深层语义理解过程如图 3 所示。首先，以候选物品为中心抽取其局部邻域子图；其次，

将子图中的实体、关系和属性信息组织为语义上下文；最后，借助大语言模型进行语义推理，生成局部主题向量 h_v^{local} 。通过该模块，模型能够在局部邻域范围内挖掘与目标物品相关的深层语义信息，为后续全局跨源语义检索和多源特征融合提供更丰富的局部语义表示。

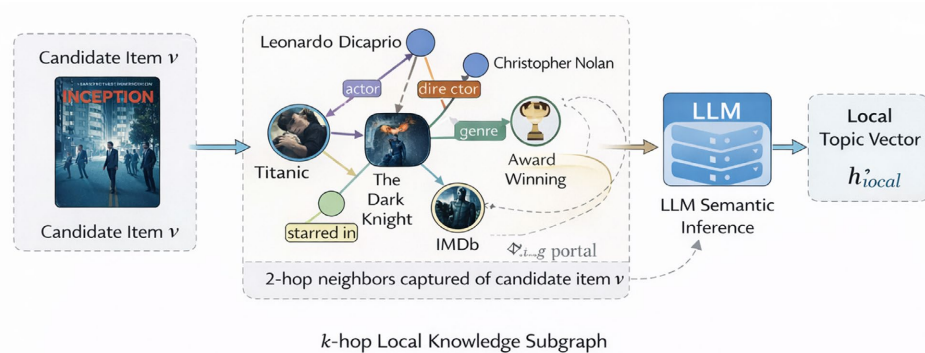


Figure 3. Schematic diagram of deep semantic understanding of local knowledge subgraphs
图 3. 局部知识子图深层语义理解示意图

对于 K -hop 局部子图的序列化，本文采取了基于关系的随机游走采样策略。具体而言，以候选物品为核心，通过深度优先搜索(DFS)提取前 10 条长度为 K 的路径，并将其转化为“实体 - 关系 - 实体”的链式文本输入 LLM。这种策略不仅保留了图的拓扑结构，还通过 LLM 的上下文推理能力捕获了隐含的属性组合语义。

3.5. 全局跨源语义检索

仅依赖局部知识子图进行语义建模，虽然能够捕捉候选物品邻域范围内的结构信息和语义特征，但在数据稀疏、冷启动以及局部邻域信息不足的场景下，仍可能存在语义覆盖不完整的问题。为进一步补充局部结构之外的背景知识，本文设计全局跨源语义检索模块，从更大范围的统一语义空间中检索与目标物品相关的外部知识，以增强模型对复杂关联关系和高阶语义依赖的建模能力[8]。

设候选物品 v 的局部语义表示为 h_v^{local} ，局部结构表示为 h_v^{KG} 。本文将二者进行组合作为语义检索查询向量：

$$q_v = [h_v^{local}; h_v^{KG}] \quad (9)$$

其中， $[\cdot]$ 表示向量拼接。基于查询向量 q_v ，在统一语义空间中检索与候选物品最相关的前 m 个语义邻居，记为

$$\mathcal{N}_v^{global} = \{c_1, c_2, \dots, c_m\} \quad (10)$$

为获得目标物品的全局语义增强表示，本文对检索得到的语义邻居进行聚合，定义为

$$h_v^{global} = \frac{1}{m} \sum_{i=1}^m c_i \quad (11)$$

其中， h_v^{global} 表示候选物品的全局语义表示，用于刻画局部知识子图之外的跨源背景语义信息。

通过全局跨源语义检索，模型能够在统一语义空间中引入与目标物品相关的外部知识补充，缓解局部邻域信息不足带来的表示偏差问题。与仅依赖局部子图建模的方法相比，该模块进一步增强了模型对跨源知识关联和复杂语义依赖的刻画能力，并为后续多源特征融合与推荐预测提供更丰富的全局语义表示。

3.6. 多源特征融合与推荐预测

在完成异构知识语义标准化、局部知识子图语义理解以及全局跨源语义检索之后，模型分别获得候选物品的多种表示信息，包括用户-物品交互表示、知识图谱结构表示、局部语义表示以及全局语义表示。为充分利用不同来源的信息，本文设计多源特征融合模块，对上述表示进行统一整合，从而学习更加完整的用户偏好表示。

设用户 u 与物品 v 的 ID 嵌入分别为 e_u 和 e_v ，知识图谱结构表示为 H_v^{KG} ，局部语义表示为 h_v^{local} ，全局语义表示为 h_v^{global} 。本文将多源特征进行拼接融合，得到物品的综合表示：

$$h_v = [e_v; h_v^{KG}; h_v^{local}; h_v^{global}] \quad (12)$$

其中， $[\cdot]$ 表示向量拼接操作。基于融合后的表示，用户与物品之间的匹配得分可表示为：

$$y_{uv} = e_u^T h_v \quad (13)$$

其中 y_{uv} 表示用户 u 对物品 v 的兴趣预测得分。根据预测得分，可进一步生成用户的 Top-N 推荐列表。

在模型训练阶段，本文采用基于隐式反馈的 Bayesian Personalized Ranking (BPR) 损失函数对模型进行优化[9]。设 v^+ 表示用户 u 的正样本物品， v^- 表示随机采样得到的负样本物品，则损失函数定义为：

$$\mathcal{L} = - \sum_{(u, v^+, v^-) \in D} \ln \sigma(y_{uv^+} - y_{uv^-}) \quad (14)$$

其中 $\sigma(\cdot)$ 为 Sigmoid 函数， D 表示训练样本集合。通过最大化正样本物品相对于负样本物品的预测得分差异，模型能够学习更加准确的用户偏好表示。

通过多源特征融合与推荐预测模块，模型能够同时利用用户交互信息、知识图谱结构信息以及多粒度语义信息，实现结构信息与语义信息的协同建模，从而提升推荐结果的准确性和鲁棒性。

4. 实验分析

4.1. 数据集与实验设置

为验证所提出模型的有效性，本文选取两个公开推荐数据集进行实验：MovieLens-1M [10] 和 Book-Crossing [11]。其中，MovieLens-1M 属于相对稠密的电影评分数据集，适合考察模型在常规推荐场景下的表现；Book-Crossing 数据集稀疏性更强，能够进一步检验模型在数据稀疏和冷启动场景下的适应能力。各数据集统计信息如表 1 所示。

Table 1. Statistical information of the dataset

表 1. 数据集统计信息

数据集	领域	用户数	物品数	交互数
MovieLens-1M	电影推荐	6040	3706	999,807
Book-Crossing	图书推荐	17,860	13,689	48,972

在数据预处理阶段，本文过滤交互次数少于 5 的用户与物品，并结合外部知识源对物品相关实体进行链接，以构建用于语义增强建模的知识图谱。对于多源异构知识，进一步采用第三章所述语义标准化模块进行统一表示。

实验中采用 8:1:1 的比例将数据划分为训练集、验证集和测试集，并在统一评测协议下开展 Top-N 推荐任务。模型训练采用 Adam 优化器，嵌入维度设为 64，局部知识子图编码层数设为 2，全局语义检索

邻居数设为 10，批大小设为 2048，其余超参数通过验证集调优确定。

4.2. 对比模型与评价指标

为验证所提模型的有效性，本文选取多类具有代表性的推荐模型作为对比方法，包括传统协同过滤模型、图推荐模型和知识图谱增强模型。其中，BPR-MF 作为经典协同过滤基线模型，采用基于隐式反馈的排序学习策略进行用户偏好建模[9]；LightGCN 作为图推荐基线模型，通过简化图卷积传播机制学习用户和物品表示[12]。在知识图谱增强推荐模型方面，选取 CKE 作为早期知识图谱嵌入方法，通过联合学习推荐任务和知识表示任务实现协同优化[13]；选择 KGAT 利用图注意力机制对用户、物品与实体之间的高阶关系进行建模[14]；选取 KGIN 通过意图感知图传播增强知识感知推荐能力[15]。各模型均采用原论文推荐的参数设置，并在相同实验环境下进行训练与评测，以保证比较公平性。

在评价指标方面，本文采用 Top-N 推荐任务中常用的 Recall@10 和 NDCG@10 对模型性能进行评估。其中，Recall@10 用于衡量模型在前 10 个推荐结果中命中用户真实偏好物品的能力；NDCG@10 在考虑命中情况的同时，进一步衡量推荐结果的排序质量。Recall@10 越高，表明模型能够覆盖更多用户感兴趣的物品；NDCG@10 越高，则说明模型能够将更相关的物品排在更靠前的位置。

4.3. 实验结果与分析

为验证所提模型 LLM-KGRec 的有效性，本文在 MovieLens-1M 和 Book-Crossing 两个数据集上，将其与多种代表性推荐模型进行对比实验。实验结果如表 2 所示。

Table 2. Comparison of recommendation performance of each model on different datasets

表 2. 各模型在不同数据上的推荐性能比较

模型	MovieLens-1M		Book-Crossing	
	Recall@10	NDCG@10	Recall@10	NDCG@10
BPR-MF	0.1852	0.0958	0.1796	0.0874
LightGCN	0.2043	0.1124	0.1854	0.1156
CKE	0.1952	0.1153	0.1799	0.0968
KGAT	0.2151	0.1223	0.1846	0.1065
KGIN	0.2341	0.1454	0.1978	0.1145
LLM-KGRec	0.2647	0.1649	0.2078	0.1368

从表 2 可以看出，所提出 LLM-KGRec 在两个数据集上均取得了最优性能，表明该模型能够有效融合用户 - 物品交互信息、知识图谱结构信息以及大语言模型生成的语义信息，从而提升推荐质量。

在 MovieLens-1M 数据集上，LLM-KGRec 的 Recall@10 和 NDCG@10 分别达到 0.2647 和 0.1649，均优于所有对比方法。具体来看，传统协同过滤模型 BPR-MF 的表现相对较弱，说明仅依赖用户 - 物品交互难以充分刻画用户复杂偏好；引入图结构传播机制的 LightGCN 在两个指标上均较 BPR-MF 有所提升，表明图神经网络能够有效增强协同信号建模能力。进一步地，结合知识图谱信息的 CKE、KGAT 和 KGIN 相较于纯协同过滤方法表现更优，其中 KGIN 在各基线模型中取得了最好的结果，说明知识感知与意图建模对于推荐任务具有积极作用。相比之下，LLM-KGRec 在 KGIN 的基础上，进一步引入大语言模型语义表示与多源融合机制，因此在两个评价指标上均实现了进一步提升。

在 Book-Crossing 数据集上，LLM-KGRec 同样取得了最优结果，其 Recall@10 和 NDCG@10 分别为 0.2078 和 0.1368。由于图书推荐场景通常具有更高的数据稀疏性，并且文本语义信息更加丰富，模型不

仅需要捕获用户与物品之间的协同关系，还需要更充分地理解物品内容语义。从实验结果来看，BPR-MF 依然表现最弱，说明传统矩阵分解方法在稀疏场景下存在明显局限；LightGCN、CKE 和 KGAT 均取得了一定提升，表明图结构建模和知识图谱辅助信息有助于缓解稀疏性问题；KGIN 在 Recall@10 上优于其他基线方法，说明其在相关项目召回方面具有一定优势。尽管部分模型在不同指标上的表现存在差异，但总体来看，LLM-KGRec 在两个指标上均保持领先，进一步验证了该模型在稀疏推荐场景下的有效性和稳定性。

4.4. 消融实验

为进一步验证 LLM-KGRec 各组成模块对推荐性能的影响，本文在 MovieLens-1M 和 Book-Crossing 两个数据集上开展消融实验。具体而言，在完整模型基础上，分别构造以下三种变体：

- (1) w/o Semantic: 去除大语言模型语义增强模块，仅保留结构化交互信息与图结构建模；
- (2) w/o KG: 去除知识图谱增强模块，仅保留协同交互表示与语义表示；
- (3) w/o Fusion: 去除多源融合模块，采用简单表示组合替代自适应融合机制。

实验结果如图 4 和图 5 所示。

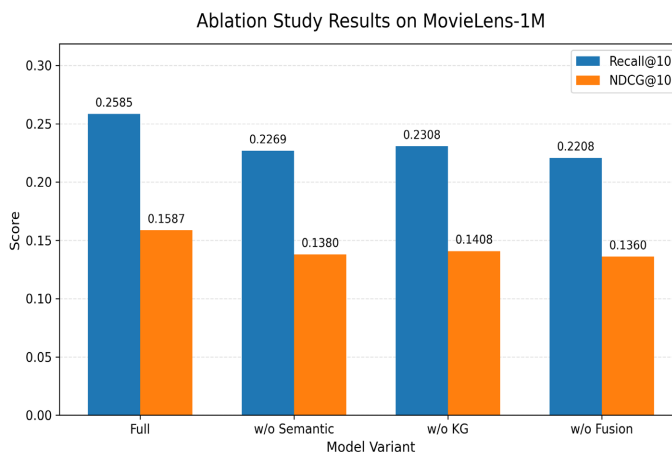


Figure 4. Shows the ablation experimental results on the MovieLens-1M dataset
图 4. 在 MovieLens-1M 数据集上的消融实验结果

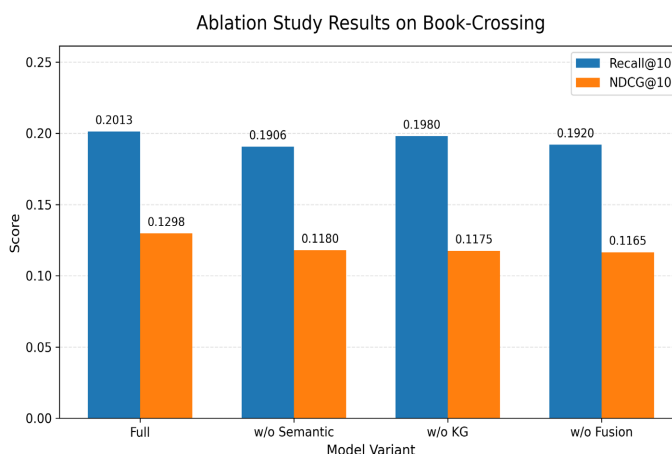


Figure 5. Ablation experimental results on the Book-Crossing dataset
图 5. 在 Book-Crossing 数据集上的消融实验结果

从结果可以看出，完整模型在两个数据集上均取得了最优性能，说明各模块的协同作用能够有效提升推荐效果。去除语义增强模块后，模型在两个数据集上的 Recall@10 和 NDCG@10 均出现明显下降，表明大语言模型提供的语义信息对用户兴趣和物品特征建模具有重要作用。去除知识图谱增强模块后，模型性能也有所下降，说明知识图谱中的结构关系信息能够为推荐任务提供有效补充。去除融合模块后，模型性能进一步下降，表明融合机制有助于提升多源信息的协同建模能力。

4.5. 参数敏感性分析

为进一步分析关键参数对模型性能的影响，本文在 MovieLens-1M 数据上对 LLM-KGRec 进行了参数敏感性实验，重点考察邻居数量 neighbor_k 和嵌入维度 recdim 对推荐性能的影响，评价指标采用 Recall@10 和 NDCG@10 。

首先，图 6 展示了不同邻居数量设置下模型性能的变化趋势。从图中可以看出，当 neighbor_k 从 5 增加到 10 时，模型性能有所提升；当其继续增大到 15 和 20 时，性能略有下降。这表明适当增加邻居数量能够帮助模型捕获更丰富的局部结构信息，从而提升推荐效果，但过多邻居会引入一定噪声，影响模型表现。综合来看， $\text{neighbor_k}=10$ 时模型性能最优。

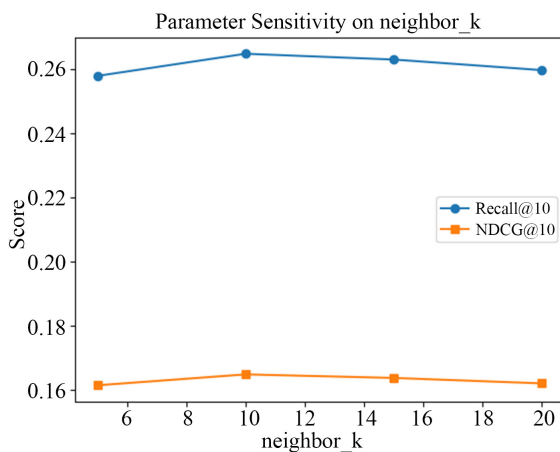


Figure 6. Parameter sensitivity analysis results of LLM-KGRec with different numbers of neighbors
图 6. 不同邻居数量下 LLM-KGRec 的参数敏感性分析结果

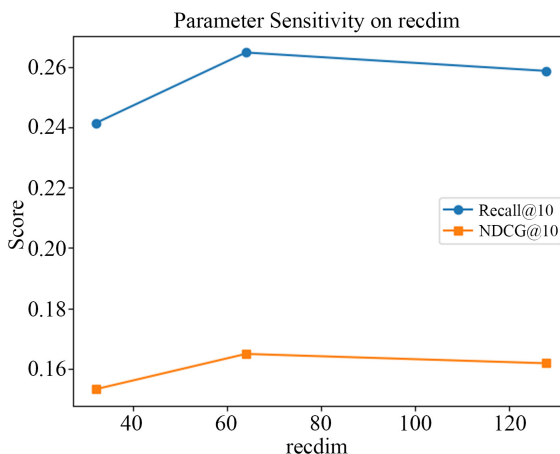


Figure 7. Parameter sensitivity analysis results of LLM-KGRec under different embedding dimensions
图 7. 不同嵌入维度下 LLM-KGRec 的参数敏感性分析结果

其次, 图 7 展示了不同嵌入维度设置下模型性能的变化情况。可以观察到, 当嵌入维度从 32 增大到 64 时, Recall@10 和 NDCG@10 均明显提升, 说明较高的嵌入维度能够增强模型对用户偏好和物品特征的表达能力; 而当维度进一步增加到 128 时, 模型性能略有下降, 表明过大的表示空间可能带来冗余信息, 并增加训练难度。因此, $recdim = 64$ 是当前实验设置下较为合适的参数选择。

总体而言, LLM-KGRec 在不同参数设置下表现出较好的稳定性。参数敏感性实验不仅验证了模型的鲁棒性, 同时也为关键参数的合理设置提供了依据。

5. 结论

本文针对传统推荐模型在语义表达能力不足和结构信息利用有限的问题, 提出了一种融合多源信息的推荐模型 LLM-KGRec。该模型通过引入知识图谱的显式结构信息与大语言模型生成的深层语义表示, 实现了对用户 - 物品关系的联合建模。

实验结果表明, LLM-KGRec 在 MovieLens-1M 和 Book-Crossing 数据集上的各项评价指标均优于多种基线方法, 验证了其在常规及稀疏推荐场景下的有效性与鲁棒性。消融实验进一步证实, 大语言模型提供的语义增强模块对性能提升贡献最为显著, 有效弥补了传统方法在深层语义挖掘上的短板。

尽管本模型取得了理想的推荐效果, 但在实际应用中仍存在一定的局限性: 首先, LLM 的引入显著增加了系统的计算开销与推理时延, 在处理超大规模实时推荐任务时仍面临挑战; 其次, 模型性能在一定程度上受限于 LLM 本身的偏见风险与“幻觉”问题, 尤其在知识图谱信息极度匮乏时, 语义增强的准确性仍有进一步约束; 此外, 对于跨源知识的动态更新与实时同步, 模型目前仍主要依赖静态知识库, 缺乏对时效性信息的快速感知能力。

综上所述, 本文通过发挥知识图谱与大语言模型的协同优势, 有效提升了推荐系统的建模深度。未来的工作将重点探索模型轻量化技术以降低推理成本, 并引入更严格的事实校验机制来抑制 LLM 的幻觉输出, 从而进一步提升模型在复杂动态场景下的实用价值。

参考文献

- [1] Li, Y., Liu, K., Satapathy, R., Wang, S. and Cambria, E. (2024) Recent Developments in Recommender Systems: A Survey [Review Article]. *IEEE Computational Intelligence Magazine*, **19**, 78-95. <https://doi.org/10.1109/mci.2024.3363984>
- [2] Gheewala, S., Xu, S. and Yeom, S. (2025) In-Depth Survey: Deep Learning in Recommender Systems—Exploring Prediction and Ranking Models, Datasets, Feature Analysis, and Emerging Trends. *Neural Computing and Applications*, **37**, 10875-10947. <https://doi.org/10.1007/s00521-024-10866-z>
- [3] Zhang, J., Zain, A.M., Zhou, K., Chen, X. and Zhang, R. (2024) A Review of Recommender Systems Based on Knowledge Graph Embedding. *Expert Systems with Applications*, **250**, Article ID: 123876. <https://doi.org/10.1016/j.eswa.2024.123876>
- [4] Zhang, Y. and Gu, X. (2024) Enhancing User and Item Representation with Collaborative Signals for KG-Based Recommendation. *Neural Computing and Applications*, **36**, 6681-6699. <https://doi.org/10.1007/s00521-024-09419-1>
- [5] Wu, L., Zheng, Z., Qiu, Z., Wang, H., Gu, H., Shen, T., et al. (2024) A Survey on Large Language Models for Recommendation. *World Wide Web*, **27**, Article No. 60. <https://doi.org/10.1007/s11280-024-01291-2>
- [6] Spillo, G., Musto, C., Mannavola, M., de Gemmis, M., Lops, P. and Semeraro, G. (2025) GAL-KARS: Exploiting LLMs for Graph Augmentation in Knowledge-Aware Recommender Systems. *Proceedings of the 33rd ACM Conference on User Modeling, Adaptation and Personalization*, New York, 16-19 June 2025, 73-82. <https://doi.org/10.1145/3699682.3728342>
- [7] Xi, Y., Liu, W., Lin, J., Cai, X., Zhu, H., Zhu, J., et al. (2024) Towards Open-World Recommendation with Knowledge Augmentation from Large Language Models. *18th ACM Conference on Recommender Systems*, Bari, 14-18 October 2024, 12-22. <https://doi.org/10.1145/3640457.3688104>
- [8] Di Palma, D. (2023) Retrieval-Augmented Recommender System: Enhancing Recommender Systems with Large Language Models. *Proceedings of the 17th ACM Conference on Recommender Systems*, Singapore, 18-22 September 2023, 1369-

1373. <https://doi.org/10.1145/3604915.3608889>
- [9] Rendle, S., Freudenthaler, C., Gantner, Z. and Schmidt-Thieme, L. (2009) BPR: Bayesian Personalized Ranking from Implicit Feedback. *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*, Montreal, 18-21 June 2009, 452-461.
- [10] Harper, F.M. and Konstan, J.A. (2015) The MovieLens Datasets: History and Context. *ACM Transactions on Interactive Intelligent Systems*, **5**, 1-19. <https://doi.org/10.1145/2827872>
- [11] Devika, P. and Milton, A. (2024) Book Recommendation System: Reviewing Different Techniques and Approaches. *International Journal on Digital Libraries*, **25**, 803-824. <https://doi.org/10.1007/s00799-024-00403-7>
- [12] He, X., Deng, K., Wang, X., Li, Y., Zhang, Y. and Wang, M. (2020) LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 25-30 July 2020, 639-648. <https://doi.org/10.1145/3397271.3401063>
- [13] Zhang, F., Yuan, N.J., Lian, D., Xie, X. and Ma, W. (2016) Collaborative Knowledge Base Embedding for Recommender Systems. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, 13-17 August 2016, 353-362. <https://doi.org/10.1145/2939672.2939673>
- [14] Wang, X., He, X., Cao, Y., Liu, M. and Chua, T. (2019) KGAT: Knowledge Graph Attention Network for Recommendation. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Anchorage, 4-8 August 2019, 950-958. <https://doi.org/10.1145/3292500.3330989>
- [15] Wang, X., Huang, T., Wang, D., Yuan, Y., Liu, Z., He, X., *et al.* (2021) Learning Intents behind Interactions with Knowledge Graph for Recommendation. *Proceedings of the Web Conference 2021*, Ljubljana, 19-23 April 2021, 878-887. <https://doi.org/10.1145/3442381.3450133>