

基于知识图谱的兴趣捕捉推荐算法

金宇, 陈红梅, 罗川

引用本文

金宇, 陈红梅, 罗川. [基于知识图谱的兴趣捕捉推荐算法](#)[J]. 计算机科学, 2024, 51(1): 133-142.

JIN Yu, CHEN Hongmei, LUO Chuan. [Interest Capturing Recommendation Based on Knowledge Graph](#) [J]. Computer Science, 2024, 51(1): 133-142.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于特征拓扑融合的黑盒图对抗攻击](#)

Black-box Graph Adversarial Attacks Based on Topology and Feature Fusion

计算机科学, 2024, 51(1): 355-362. <https://doi.org/10.11896/jsjcx.230600127>

[基于生成式对抗网络和正类无标签学习的知识图谱补全算法](#)

Knowledge Graph Completion Algorithm Based on Generative Adversarial Network and Positive and Unlabeled Learning

计算机科学, 2024, 51(1): 310-315. <https://doi.org/10.11896/jsjcx.230300006>

[生成扩散模型研究综述](#)

Survey on Generative Diffusion Model

计算机科学, 2024, 51(1): 273-283. <https://doi.org/10.11896/jsjcx.230300057>

[限定域关系抽取技术研究综述](#)

Survey on Domain Limited Relation Extraction

计算机科学, 2024, 51(1): 252-265. <https://doi.org/10.11896/jsjcx.230200100>

[基于双重动态记忆网络的弱监督视频异常检测](#)

Weakly Supervised Video Anomaly Detection Based on Dual Dynamic Memory Network

计算机科学, 2024, 51(1): 243-251. <https://doi.org/10.11896/jsjcx.230300134>

基于知识图谱的兴趣捕捉推荐算法

金 宇¹ 陈红梅^{2,3,4,5} 罗 川⁶

1 西南交通大学唐山研究院 河北 唐山 063010

2 西南交通大学计算机与人工智能学院 成都 611756

3 可持续城市交通智能化教育部工程研究中心 成都 611756

4 综合交通大数据应用技术国家工程实验室 成都 611756

5 四川省制造业产业链协同与信息化支撑技术重点实验室 成都 611133

6 四川大学计算机学院 成都 610065

(jinyu@my.swjtu.edu.cn)

摘 要 知识图谱作为一种辅助信息,可以为推荐系统提供更多的上下文信息和语义关联信息,从而提高推荐的准确性和可解释性。通过将项目映射到知识图谱中,推荐系统可以将从知识图谱中学习到的外部知识注入到用户和项目的表示中,进而增强用户和项目的表示。但在学习用户偏好时,基于图神经网络的知识图谱推荐主要通过项目实体利用知识图谱中的属性信息和关系信息等知识信息。由于用户节点并不与知识图谱直接相连,这就导致不同的关系信息和属性信息在语义上和用户偏好方面是独立的,缺乏关联。这表明,基于知识图谱的推荐难以根据知识图谱中的信息来准确捕获用户的细粒度偏好。因此,针对用户细粒度兴趣难以捕捉的问题,提出了一种基于知识图谱的兴趣捕捉推荐算法。该算法利用知识图谱中的关系和属性信息来学习用户的兴趣,并增强用户和项目的嵌入表示。为了充分利用知识图谱中的关系信息,设计了关系兴趣模块以学习用户对不同关系的细粒度兴趣。该模块将每个兴趣表示为知识图谱中关系向量的组合,并利用图卷积神经网络在用户项目图和知识图谱中传递用户兴趣以学习用户和项目的嵌入表示。此外,还设计了属性兴趣模块以学习用户对不同属性的细粒度兴趣。该模块采用切分嵌入的方法为用户和项目匹配与之相似的属性,并使用与关系兴趣模块中相似的方法进行消息传播。最终,在两个基准数据集上进行实验,实验结果验证了该方法的有效性和可行性。

关键词: 推荐算法;深度学习;知识图谱;图神经网络

中图分类号 TP391

Interest Capturing Recommendation Based on Knowledge Graph

JIN Yu¹, CHEN Hongmei^{2,3,4,5} and LUO Chuan⁶

1 Tangshan Research Institute, Southwest Jiaotong University, Tangshan, Hebei 063010, China

2 School of Computing and Artificial Intelligence, Southwest Jiaotong University, Chengdu 611756, China

3 Sustainable Urban Transportation Intelligent Engineering Research Center of the Ministry of Education, Chengdu 611756, China

4 National Engineering Laboratory of Comprehensive Transportation Big Data Application Technology, Chengdu 611756, China

5 Sichuan Provincial Key Laboratory of Manufacturing Industry Chain Collaboration and Information Technology Support Technology, Chengdu 611756, China

6 College of Computer Science, Sichuan University, Chengdu 610065, China

Abstract As a kind of auxiliary information, knowledge graph can provide more context information and semantic association information for the recommendation system, thereby improving the accuracy and interpretability of the recommendation. By mapping items into knowledge graphs, recommender systems can inject external knowledge learned from knowledge graphs into user and item representations, thereby enhancing user and item representations. However, when learning user preferences, the knowledge graph recommendation based on graph neural network mainly utilizes knowledge information such as attribute and relationship information in the knowledge graph through project entities. Since user nodes are not directly connected to the knowledge

到稿日期:2023-05-01 返修日期:2023-09-28

基金项目:国家自然科学基金(61976182, 62076171);四川省自然科学基金(2022NSFSC0898);四川省科技成果转化示范项目(2022ZHCG0005)

This work was supported by the National Natural Science Foundation of China(61976182, 62076171), Natural Science Foundation of Sichuan Province, China(2022NSFSC0898) and Sichuan Scientific and Technological Achievements Transfer and Transformation Demonstration Project of China(2022ZHCG0005).

通信作者:陈红梅(hmchen@swjtu.edu.cn)

graph, different relational and attribute information are semantically independent and lack correlation regarding user preferences. It is difficult for the recommendation based on the knowledge graph to accurately capture user's fine-grained preferences based on the information in the knowledge graph. Therefore, to address the difficulty in capturing users' fine-grained interests, this paper proposes an interest-capturing recommendation algorithm based on a knowledge graph (KGICR). The algorithm leverages the relational and attribute information in knowledge graphs to learn user interests and improve the embedding representations of users and items. To fully utilize the relational information in the knowledge graph, a relational interest module is designed to learn users' fine-grained interests in different relations. This module represents each interest as a combination of relation vectors in the knowledge graph and employs a graph convolutional neural network to transfer user interests in the user-item graph and the knowledge graph to learn user and item embedding representations. Furthermore, an attribute interest module is also designed to learn users' fine-grained interests in different attributes. This module matches users and items with similar attributes by splitting and embedding and uses a similar method to the relational interest module for message propagation. Finally, experiments are conducted on two benchmark datasets, and the experimental results demonstrate the effectiveness and feasibility of the proposed method.

Keywords Recommendation algorithm, Deep learning, Knowledge graph, Graph neural network

1 引言

随着信息技术的发展和在线信息的爆炸式增长,信息过载问题日益严重。目前,作为信息消费者,从海量信息中找到自己感兴趣的信息是一件非常困难的事情;作为信息生产者,精确地捕捉客户兴趣并向客户推送需要的信息同样具有很大的挑战^[1]。为了解决信息过载问题,提升用户体验,推荐系统应运而生。推荐系统是利用收集的用户对项目的偏好、用户特征、项目特征等内容,用特定的知识表示方式进行处理存储;再利用机器学习或者统计学习的相关算法分析已有数据,针对特定的用户需求偏好为其推荐相应项目,帮助用户做出决策的智能系统^[2]。推荐系统 (Recommendation System) 主要分为基于协同过滤 (Collaborative Filtering, CF) 的推荐系统^[3]、基于内容的推荐系统^[4]和混合推荐系统^[5]。此外,还有一些研究利用矩阵分解等方法进行推荐。如图 1 所示,基于 CF 的推荐系统由于能有效地捕捉用户偏好,并且易于在多种场景下实现,且无需在基于内容的推荐系统中进行特征提取,因此得到了广泛的应用。然而,以上几种方法虽提升了推荐效果,但仍存在着数据稀疏和冷启动问题。




图 基于用户的协同过滤
Fig. 1 User-based collaborative filtering

为了解决传统推荐算法存在的数据稀疏和冷启动问题^[6],在推荐系统中引入辅助信息的方法受到许多关注,如引入社交网络、知识图谱 (Knowledge Graph, KG)、用户/项目属性、图像或上下文等信息。其中,知识图谱通常含有关于项目的大量关系和事实。知识图谱是一种有向异构图,其中节点对应于实体,边对应于关系,实体和关系以三元组 (头实体、关系、尾实体) 的形式形成一个网络。目前有关基于知识图谱的

推荐系统的研究主要集中于丰富项目/用户的表示信息,即利用知识图谱中与用户有交互的项目节点的属性信息,通过邻域聚合等方法增强项目表示,进而增强用户表示。但利用知识图谱进行用户兴趣捕捉的方法还存在缺陷,例如目前的基于知识图谱的推荐系统不能细致地捕捉用户对知识图谱中关系和属性的细粒度兴趣。另外,对知识图谱的三元组中关系向量的应用也较为不足,大量的研究工作聚焦于如何利用三元组中的实体信息,而忽略了关系向量这一重要信息。

同时,深度学习 (Deep Learning, DL) 因为具有强大的学习能力,在推荐领域占据了越来越重要的地位。与传统的推荐架构相比,基于深度学习的推荐系统通过组合低层特征形成更加稠密的高层语义抽象,可以更好地进行用户和项目交互的表示学习。因此,很多研究者利用循环神经网络 (Recurrent Neural Network, RNN)、卷积神经网络 (Convolutional Neural Network, CNN)、图神经网络 (Graph Neural Network, GNN) 等深度学习模型处理推荐系统的各种问题。其中, GNN^[7] 是一种连接模型,通过图的节点之间的消息传递来捕捉图的依赖关系,使用图结构表示输入的神经网络,目标是学习图中各节点的状态信息 (包含邻接信息)。图神经网络采用嵌入传播来迭代聚合邻域嵌入,通过堆叠传播层,每个节点可以访问高阶邻居的信息,而不是像传统方法那样只访问一阶邻居的信息。基于图神经网络的方法具有处理结构数据和探索结构信息的优势,但同时也存在着训练时间长、可解释性差等缺点。

针对上述问题,在 KGAT^[8] 模型的基础上,本文提出了一种基于知识图谱的意图捕捉推荐算法 (Interest Capturing Recommendation Based on Knowledge Graph, KGICR) 用于推荐任务。该算法利用知识图谱中的关系和属性信息来学习用户的兴趣,并增强用户和项目的嵌入表示。首先,为了充分利用知识图谱中的关系信息,设计了关系兴趣模块以学习用户对不同关系的细粒度兴趣。关系兴趣模块将每个兴趣表示为知识图谱中关系向量的组合,并利用图卷积神经网络在用户-项目图和知识图谱中传递用户兴趣以学习用户和项目的嵌入表示。然后,还设计了属性兴趣模块以学习用户对不同属性的细粒度兴趣。该模块采用切分嵌入的方法为用户和项目匹配与它们相似的属性,并使用与关系兴趣模块中相似的方法

进行消息传播。最后,利用内积方法评估用户项目相似度,生成 TOP-K 推荐。为了评估 KGICR 的推荐性能,在不同的数据集上将其与相关算法进行了比较实验。实验结果表明,本文提出的方法在所有数据集上的性能都优于比较方法。本文工作的主要贡献如下:

1)针对知识图谱中的关系和属性信息,分别设计了关系兴趣模块和属性兴趣模块,并将其应用在知识图谱推荐场景中,对用户的细粒度兴趣进行捕捉。

2)在 Amazon-Book 和 Last.FM 数据集上将本文方法与相关算法进行了比较,实验结果验证了所提方法的有效性。

本文第 2 章介绍了相关的工作;第 3 章介绍了 KGICR 模型的具体细节;第 4 章介绍了数据集、实验设置、实验结果、结果分析以及案例研究;最后总结全文并展望未来。

2 相关工作

2.1 传统推荐算法

在早期研究中,基于内容的推荐算法最早被提出和使用。此后,Goldberg 等^[9]提出基于协同过滤的推荐算法,即根据用户项目交互分析用户潜在需求,为用户推荐其可能感兴趣的项目。混合推荐算法的出现弥补了传统推荐算法的一些弊端,其将传统算法进行组合,提升了算法的推荐性能。

随着深度学习的发展,神经网络逐渐被应用到推荐算法中。Covington 等^[10]提出了一种基于深度神经网络的 YouTube 视频推荐算法,该算法将用户信息和项目信息以 embedding 嵌入的形式输入到深度神经网络中,一定程度上缓解了数据稀疏和冷启动问题,使得模型的推荐性能较以往取得了较大的提升。此后,Cheng 等^[11]提出了一种 Wide&Deep 推荐模型,同时对线性模型和深度神经网络进行训练,以弥补深度神经网络容易过拟合的缺点,使得该模型同时具有泛化和记忆的能力。近年来,注意力机制在神经网络中的作用受到了广泛关注。Zhou 等^[12]提出了一种深度兴趣网络推荐模型(Deep Interest Network,DIN),该模型利用注意力机制对用户兴趣点进行加权池化,能够更好地反映用户在不同兴趣点上的偏好程度,使得多层神经网络的学习有了偏好,从而提高模型的推荐效果。此后,Donkers 等^[13]将 GRU(Gate Recurrent Unit)门控机制应用到循环神经网络中,通过抓取会话中点击之间的依赖关系进行推荐。随着图神经网络的发展,Wu 等^[14]提出了一个基于图神经网络的会话推荐模型,将图神经网络应用到推荐领域中,相较于以往的会话推荐模型,推荐性能有了较大的提升。He 等^[15]利用卷积网络强大的消息传递性能,在 NGCF^[16]推荐模型的基础上采用去除相邻系节点的内积操作进行聚合的方式,既优化了算法的时间复杂度,又提升了推荐性能。Lin 等^[17]在图神经网络框架的基础上,利用其改进后的对比学习方法,提出了一种基于邻域增强对比学习的图协同过滤模型。

相较于传统的协同过滤算法,基于深度学习的推荐算法能够通过学习数据的低维度表示来处理稀疏性数据。特别是基于图神经网络的推荐算法将图神经网络应用到推荐系统中,利用图神经网络对用户和物品之间的复杂关系进行建模,从而实现更加准确和个性化的推荐。但相较于基于知识图谱

的推荐算法,基于图神经网络的推荐算法只能捕捉节点之间的相似性和关系,缺乏对边信息的表示,对推荐的解释性也不够清晰。

2.2 基于知识图谱的推荐算法

KG 是一种异构图,其节点对应于实体,边对应于关系,实体和关系以三元组(头实体、关系、尾实体)的形式形成一个异构图。将知识图谱引入推荐系统有以下几个优势。1)可以提供丰富的语义信息,使得推荐系统能够推荐更加丰富和多样化的内容。例如,基于知识图谱的推荐系统可以将用户之前喜欢的电影、音乐等进行语义化的链接,从而推荐更多相关的内容。2)能够将各种信息进行语义化的链接,使得推荐系统能够更好地理解用户的需求和兴趣,从而提高推荐效果。通过分析知识图谱中的实体、属性和关系,可以实现更为准确的个性化推荐。3)提供了一个结构化的模型,可以更加清晰地表达推荐系统的推荐逻辑,从而使得推荐结果更加易于理解和解释。目前,基于知识图谱的推荐方法主要有 3 类:基于嵌入的知识图谱推荐、基于路径的知识图谱推荐、基于混合方法的知识图谱推荐。

基于嵌入的知识图谱推荐通过将用户、项目和属性嵌入到一个低维向量空间中,建立起用户、项目和属性之间的关系,从而实现推荐。如 Wang 等^[18]提出的深度知识感知(Deep Knowledge-aware Network,DKN)推荐模型将知识图谱作为边信息,利用卷积神经网络融合新闻标题中的单词和知识图谱中的相关实体的嵌入表示,并设计了一个注意力模块以考虑用户兴趣的变化,根据用户的交互历史,动态调整不同新闻标题的权重。Cao 等^[19]提出的用户偏好知识图(Knowledge Graph Recommendation: Towards a Better Understanding of User Preferences,KTUP)模型将用户和项目的交互视为知识图谱中实体间的一种关系,通过对推荐任务和知识图谱补全任务进行联合训练,将从知识图谱中学习到的信息传递到用户-项目交互预测中。基于路径的知识图谱推荐方法利用知识图谱中实体之间的关系,通过路径推理对用户偏好进行预测,进而生成推荐结果,该方法生成的推荐结果可解释性较强。Hu 等^[20]提出的基于元路径上下文的神经协同注意力模型利用元路径信息来捕捉不同类型的物品之间的关系,同时考虑用户的兴趣和历史行为,并使用 GCN 来对加权后的关系图进行表示学习,生成元路径上下文表示;之后利用注意力机制来学习用户和元路径上下文之间的关系,并将这些关系结合起来,生成用户兴趣表示,用于推荐。Wang 等^[21]提出的知识图谱用户偏好传播网络(RippleNet)模型在知识图谱上传播用户偏好,并以该用户为根构建路径。RippleNet 在贝叶斯框架中将偏好传播和知识图谱嵌入的正则化相统一,提高了模型点击率预测的性能。基于混合方法的知识图谱推荐结合基于嵌入和基于路径的方法,通过提取知识图谱的结构来学习用户和项目的嵌入。该类方法目前比较主流的是结合图神经网络的知识图谱推荐。如 Wang 等^[22]提出的知识图卷积网络(Knowledge Graph Convolutional Network,KGCN)模型利用非谱图卷积方法,将节点邻域扩展到多跳,以捕获高阶结构信息和用户偏好,并将用户关系得分计算为邻居权重。Wang 等^[8]提出的知识图谱注意力网络

(Knowledge Graph Attention Network, KGAT)模型对知识图谱中的高阶关系进行显式建模。该模型还提出了一种新颖的多层次注意力机制,用于同时考虑用户-项目交互和知识图谱中的实体和关系。具体来说,它包括局部注意力和全局注意力两个层次,局部注意力用于捕捉用户-项目交互中的局部特征,全局注意力用于考虑知识图谱中的全局信息。

尽管以上方法,特别是 RippleNet, KGCN 和 KGAT 等方法,已经取得成功,证明了将知识图谱与图神经网络结合进行推荐的先进性,但这些方法对用户在知识图谱中的关系和属性的细粒度兴趣建模的能力有限。例如,在电影推荐中,用户可能对某个演员、导演或者电影风格有特定的兴趣,但这些信息往往被简化为与实体之间的关系,而无法进行用户的细粒度兴趣建模。针对以上方法的不足,本文提出了一种基于知识图谱的兴趣捕捉推荐算法 KGICR,用于捕捉用户对知识图谱中关系和属性的细粒度兴趣。

3 KGICR 模型

本章将详细描述所提出的 KGICR 模型的结构,如图 2 所示。模型主要由关系兴趣模块、属性兴趣模块和预测模块 3 个模块组成。其中,关系兴趣模块又包括关系兴趣建模模块和关系兴趣传播模块两部分。在关系兴趣建模模块,首先用多个用户潜在兴趣来描述用户-项目关系,并将每个兴趣

表述为知识图谱关系向量的组合。同时为了使不同兴趣彼此独立,该部分引入了一个独立性建模模块;在关系兴趣传播模块中,为了将用户对知识图谱中不同关系的兴趣融合至最终的用户表示,通过在图卷积网络上传播用户关于关系的兴趣表示和项目表示来生成该模块的最终用户和项目表示。类似地,属性兴趣模块分为属性兴趣建模模块和属性兴趣传播模块两个部分。在属性兴趣建模模块中,首先将项目 and 用户的初始嵌入进行分割,为每个部分匹配相应的属性类别。接着,利用相似性预测函数预测用户对知识图谱中属性节点的感兴趣程度。最后,将用户对项目的兴趣与用户对属性的兴趣加以整合。在属性兴趣传播模块中,采用与关系兴趣传播模块类似的流程,通过图卷积网络获取高阶邻域表示,生成属于属性兴趣模块的用户表示和项目表示。最后,将两个模块的用户表示和项目表示分别进行拼接,得到最终的用户表示和项目表示,并对两者进行内积操作,得到两者的相似性得分。推荐场景中通常存在着用户-项目交互历史(如购买和点击等),可以借助用户-项目交互图表示这些信息。假设有 m 个用户 $\mathcal{U}=\{u_1, u_2, \dots, u_m\}$ 和 n 个项目 $\mathcal{I}=\{i_1, i_2, \dots, i_n\}$,那么可以将用户-项目交互图表示为 $\mathcal{O}=\{(u, i) | u \in \mathcal{U}, i \in \mathcal{I}\}$,其中 $\mathcal{U}$ 表示用户的集合, $\mathcal{I}$ 表示项目的集合。此外,根据用户-项目交互信息,可以生成交互矩阵 $\mathbf{Y}=\mathbb{R}^{m \times n}$ 。矩阵中, $y_{ui}=1$ 代表用户 u 和项目 i 存在交互, $y_{ui}=0$ 代表二者不存在交互。




图 2 KGICR 整体结构

Fig. 2 Overall structure of KGICR

知识图谱以异构图或异构信息网络的形式存储现实世界的结构化信息,如项目属性、分类和外部常识等信息。设 $\mathcal{E}$ 是实体的集合, $\mathcal{R}$ 是关系集,则知识图谱可以表示为: $\mathcal{G}=\{(h, r, t) | h \in \mathcal{E}, r \in \mathcal{R}, t \in \mathcal{E}\}$ 。其中,每个 (h, r, t) 都是一个具体的三元组,每个三元组都描述了从头实体 h 到尾实体 t 之间存在关系 r 。 $\mathcal{R}$ 中包含正向关系和反向关系。

3.1 关系兴趣模块

3.1.1 关系兴趣建模模块

在推荐系统中,知识图谱中的关系对于用户兴趣的捕捉

在电影推荐系统中有很大的帮助。例如,电影之间的关系可以包括导演、演员、类型等。通过分析这些信息,可以推断出用户在选择电影时更加看重哪些关系,从而更准确地捕捉用户兴趣,提高推荐系统的准确性。为了捕捉用户对知识图谱中关系的兴趣,KTPU^[19]中提出了一个简单的解决方案,即将每种兴趣与一个知识图谱关系相结合。然而,此解决方案仅仅独立考虑单个关系,而没有考虑到关系的交互和组合,这样难以细化地对用户兴趣进行捕捉。鉴于此,本章知识图谱中用关系的不同组合表示用户的不同兴趣,并设计了注意力

机制来捕捉用户兴趣。假设 P 是用户兴趣的集合,则用户某一兴趣的嵌入向量具体表示如下:

$$\mathbf{e}_p = \sum_{r \in \mathcal{R}} \alpha(r, p) \mathbf{e}_r \quad (1)$$

其中, $\mathbf{e}_p$ 是用户某一兴趣的嵌入向量, $\mathbf{e}_r$ 是关系 r 的嵌入向量。为了衡量不同关系的重要程度,每个关系都使用多层注意力机制生成相应的注意力得分。具体设计如下:

$$f(r, p) = \mathbf{h}^T \text{ReLU}(\mathbf{W}(r \odot p) + b) \quad (2)$$

其中, $\mathbf{W}$ 表示输入层到隐藏层的权重矩阵, b 是为了防止过拟合的偏置项, $\mathbf{h}^T$ 是权重向量。之后,使用 softmax 函数对 $f(r, p)$ 进行归一化:

$$\alpha(r, p) = \frac{\exp(f(r, p))}{\sum_{r' \in \mathcal{R}} \exp(f(r', p))} \quad (3)$$

此外,不同的兴趣应该反映用户不同方面的偏好。如果一个兴趣与其他兴趣高度相似,那么该兴趣对应的用户-项目交互信息可能是冗余的,信息量也较少;相反,包含特有偏好信息的兴趣将为模型提供有价值的信息以更好地学习用户偏好。为了提升模型的推荐性能和可解释性,有必要使不同兴趣的表示相互独立。因此,引入了距离相关的独立性模块^[23],该模块能够判断两个变量之间是否存在关联,只有当相关性系数为零时,两个变量才相互独立。通过最小化不同兴趣之间的相关性系数,才能降低兴趣之间的冗余性,使每个兴趣向量反映用户不同方面的偏好。其公式如下:

$$\mathcal{L}_{\text{IND}} = \sum_{p, p' \in \mathcal{P}, p \neq p'} d\text{Cor}(\mathbf{e}_p, \mathbf{e}_{p'}) \quad (4)$$

其中, $d\text{Cor}()$ 是不同兴趣之间的距离相关函数,具体如下:

$$d\text{Cor}(\mathbf{e}_p, \mathbf{e}_{p'}) = \frac{d\text{Cov}(\mathbf{e}_p, \mathbf{e}_{p'})}{\sqrt{d\text{Var}(\mathbf{e}_p) \cdot d\text{Var}(\mathbf{e}_{p'})}} \quad (5)$$

其中, $d\text{Cov}()$ 是 $\mathbf{e}_p$ 和 $\mathbf{e}_{p'}$ 的距离协方差, $d\text{Var}()$ 用来计算 $\mathbf{e}_p$ 和 $\mathbf{e}_{p'}$ 各自的距离方差。优化这种损失有利于增强不同兴趣之间的差异性,更符合真实场景中的用户兴趣特点,可以增强模型的可解释性。

3.1.2 关系兴趣传播模块

在对关系兴趣进行建模之后,模型基于图神经网络的框架继续进行用户和项目的表示学习,对用户和项目的嵌入进行更新。参考协同过滤推荐,假设兴趣相似的用户会喜欢相似的项目,即其偏好模式是相似的,在此条件的基础上,进行细粒度用户兴趣的捕捉。结合前面得到的兴趣嵌入,构造了一个用户关系兴趣图。如图3所示,该图在用户-项目交互图的基础上,在用户节点和项目节点之间添加兴趣节点。在该图中,使用 $\mathcal{N}_u = \{(p, i) | (u, p, i) \in C\}$ 表示兴趣分布和其周围的一阶邻域项目。通过整合兴趣分布和其周围的一阶邻域项目,可以将用户 u 表示为:

$$\mathbf{e}_u^{(1)} = f_u(\{(e_u^{(0)}, \mathbf{e}_p, \mathbf{e}_i^{(0)}) | (p, i) \in \mathcal{N}_u\}) \quad (6)$$

其中, $\mathbf{e}_u^{(1)} \in \mathbb{R}^d$ 是用户 u 的表示, $\mathbf{e}_u^{(0)}$ 和 $\mathbf{e}_i^{(0)}$ 分别是用户和项目的初始嵌入; $f_u()$ 是用于根据用户-兴趣-项目三元组 (u, p, i) 生成用户表示的聚合函数。 $f_u()$ 可以被实现为:

$$\mathbf{e}_u^{(1)} = \frac{1}{|\mathcal{N}_u|} \sum_{(p, i) \in \mathcal{N}_u} \beta(u, p) \mathbf{e}_p \odot \mathbf{e}_i^{(0)} \quad (7)$$

其中, $\odot$ 是元素积运算符。不同的兴趣将导致用户产生不同的行为, $\beta(u, p)$ 是衡量不同兴趣对用户的重要程度的注意力机制。 $\beta(u, p)$ 的计算式如下:

$$\beta(u, p) = \frac{\exp(\mathbf{e}_p^T \mathbf{e}_u^{(0)})}{\sum_{p' \in \mathcal{P}} \exp(\mathbf{e}_{p'}^T \mathbf{e}_u^{(0)})} \quad (8)$$

通过上述计算,用户表示中蕴含了其兴趣感知信息和与项目交互的历史信息,这为后续实现个性化推荐奠定了基础。




图3 用户关系兴趣图

Fig. 3 Userrelation interest graph

项目实体是基于知识图谱的推荐系统的核心组成部分之一,连接用户-项目图和知识图谱。相较于用户节点,项目节点可以更直接地学习知识图谱中的上下文信息和语义信息。知识图谱中与项目实体相连的实体可作为属性实体,属性实体可以帮助推荐算法更好地理解项目实体的特点和用户的需求^[24]。具体来说,用 $\mathcal{N}_i = \{(r, v) | (i, r, v) \in \mathcal{G}\}$ 表示项目 i 的属性和邻域信息,则项目 i 可以表示为:

$$\mathbf{e}_i^{(1)} = f_{\text{KG}}(\{(\mathbf{e}_i^{(0)}, \mathbf{e}_r, \mathbf{e}_v^{(0)}) | (r, v) \in \mathcal{N}_i\}) \quad (9)$$

其中, $\mathbf{e}_i^{(1)} \in \mathbb{R}^d$ 是项目聚合其属性信息及其他一阶邻域信息后生成的嵌入表示, $f_{\text{KG}}()$ 是从每个三元组 (i, r, v) 中提取和聚合信息的聚合函数。

除此之外,知识图谱中的同一实体在不同的三元组中可能具有不同的语义信息。当然,这也是知识图谱的优势所在,即其能够从不同的角度描述实体,为推荐系统提供更全面的信息^[25]。例如,在“使用”这个关系下,一款电脑品牌可以被描述为一种电脑设备,具有优秀的性能、设计和用户体验,常用于个人和商业用途。而在“品牌价值”这个关系下,一款电脑品牌可以被描述为一种品牌资产,代表着品质、信任和忠诚等价值观,成为了一种具有影响力和竞争力的品牌。综合而言,同一款电脑品牌在不同关系下具有不同的特征和意义。考虑到这种情况,将关系上下文建模为:

$$\mathbf{e}_i^{(1)} = \frac{1}{|\mathcal{N}_i|} \sum_{(r, v) \in \mathcal{N}_i} \mathbf{e}_r \odot \mathbf{e}_v^{(0)} \quad (10)$$

其中, $\mathbf{e}_v^{(0)}$ 是实体 v 的嵌入表示。通过将关系 r 建模为投影算子,为每个三元组 (i, r, v) 设计了一个关系化信息元件 $\mathbf{e}_r \odot \mathbf{e}_v^{(0)}$ 。通过此元件,即使三元组中含有相同的实体,也能借助关系嵌入准确地表示出该三元组的语义信息。

在完成了对用户和项目的一阶连通性建模之后,借助图卷积网络,继续堆叠更多的卷积层,则可以捕获用户和项目的高阶邻域信息。具体计算如下:

$$\mathbf{e}_u^{(l)} = f_u(\{(\mathbf{e}_u^{(l-1)}, \mathbf{e}_p, \mathbf{e}_i^{(l-1)}) | (p, i) \in \mathcal{N}_u\}) \quad (11)$$

$$\mathbf{e}_i^{(l)} = f_{\text{KG}}(\{(\mathbf{e}_i^{(l-1)}, \mathbf{e}_r, \mathbf{e}_v^{(l-1)}) | (r, v) \in \mathcal{N}_i\}) \quad (12)$$

其中, $\mathbf{e}_u^{(l-1)}$, $\mathbf{e}_i^{(l-1)}$ 和 $\mathbf{e}_v^{(l-1)}$ 分别是用户、项目、实体的第 $(l-1)$ 层的表示。得益于之前的关系兴趣建模块,这些表示能存储多跳路径的整体语义,并突出了关系依赖。

在经过 l 层的传播后,可以获得每层的用户和项目的嵌入表示,分别将它们累加起来,就可以得到最终的用户

和项目的嵌入表示：

$$\mathbf{e}_u^r = \mathbf{e}_u^{(0)} + \dots + \mathbf{e}_u^{(l)} \quad (13)$$

$$\mathbf{e}_i^r = \mathbf{e}_i^{(0)} + \dots + \mathbf{e}_i^{(l)} \quad (14)$$

3.2 属性兴趣模块

3.2.1 项目表示建模模块

在实际生活中,用户很可能因为项目的某种属性而喜欢具有相同属性的项目^[26]。此外,在知识图谱中,一个项目实体可能具有多个属性实体邻居,并且项目和属性之间对应着多种关系。因此,考虑到知识图谱中属性实体包含丰富的语义信息以及属性实体与项目实体之间关系的多样性,该模块将通过属性信息来捕捉用户兴趣,并利用属性信息对用户和项目表示进行增强。

在知识图谱中,一个实体与其不同的邻居常常有着不同的关系。如图4所示,为了将实体建模为纯初始状态,不受语义污染,将每个关系视为一个属性空间,并将每个实体嵌入切分为相应的属性空间维度。具体计算过程如下:

$$\mathcal{E}^{\text{atr}} = \{(\mathbf{e}_i^{r_1}, \mathbf{e}_i^{r_2}, \dots, \mathbf{e}_i^{r_M}) \mid i \in \mathcal{E}, M = |\mathcal{R}|\} \quad (15)$$

$$\mathbf{e}_i^{r_j} = \frac{1}{|\mathcal{N}_i^{r_j}|} \sum_{j \in \mathcal{N}_i^{r_j}} \mathbf{e}_j^{r_j} \quad (16)$$

其中, $\mathbf{e}_i^{r_m} \in \mathbb{R}^{d^m}$ 表示实体 i 在对应的属性空间 r_m 中的嵌入, d^m 是嵌入向量的维度。通过以上两个公式聚合具有相同关系的属性,并对聚合结果进行平均池化。对于没有对应关系的邻域属性,使用零向量进行填充。最后,采用拼接的操作将实体在不同关系中的向量表达融合为实体的属性信息。如下所示:

$$\mathbf{e}_i^{(0)} = \mathbf{e}_i^{r_1} \parallel \mathbf{e}_i^{r_2} \parallel \dots \parallel \mathbf{e}_i^{r_M} \quad (17)$$

上式说明了属性如何在特定的元素位置范围内表示。此外,同一种类型的属性被放置在所有实体的相同元素位置,这种拼接形式避免了属性交互并保持了属性之间的语义独立性。




图4 属性建模过程图

Fig. 4 Property modeling process graph

由于知识图谱中的属性实体与项目实体直接相连,因此首先使用项目的属性信息来增强项目实体的表示。具体来说,模型将每个项目的属性特征与其初始表示进行拼接,并输入到图卷积网络中进行信息传递和特征学习。通过多层图

卷积网络的堆叠,模型得到每个项目的最终表示,其中包含了项目的属性信息和它们之间的相互作用信息。

通过以上操作,获得了聚合了一阶近邻属性的初始实体表示。接下来通过图卷积网络来获取高阶邻域信息,如同关系兴趣传播模块,用图卷积网络将高阶邻居信息聚合到中心节点,以获得拥有更多信息的项目表示。首先,聚合具有相同关系的邻居属性实体;然后,为了学习更全面的项目表示,聚合了不同关系的邻居属性实体。在第 l 层,项目实体嵌入被递归地表示为:

$$\mathbf{e}_i^{(l)} = \sum_{r_j \in \mathcal{R}} \frac{1}{|\mathcal{N}_i^{r_j}|} \sum_{j \in \mathcal{N}_i^{r_j}} \mathbf{e}_j^{(l-1)} \quad (18)$$

为了避免高阶邻居噪声问题,重新从元件位置的角度来审视实体嵌入 $\mathbf{e}_i^r$ 。在不损失普遍性的情况下,将 $\mathbf{e}_i^r$ 构造为:

$$\mathbf{e}_i^r = \mathbf{e}_i^{r_1} \parallel \mathbf{e}_i^{r_2} \parallel \dots \parallel \mathbf{e}_i^{r_M} \quad (19)$$

其中, $\mathbf{e}_i^{r_m} \in \mathbb{R}^{d^m}$ 是 $\mathbf{e}_i^r \in \mathbb{R}^D$ 的截断向量。观察 $\mathbf{e}_i^{r_m}$ 的生成过程可以发现, $\mathbf{e}_i^{r_m}$ 是通过学习项目实体 i 在 r_m 属性空间 r_m 中的邻域信息生成的,没有学习任何其他属性空间中的嵌入信息。如图4所示, $\mathbf{e}_i^{r_1}$ 仅通过学习 $\mathbf{e}_2^{r_1}$, $\mathbf{e}_3^{r_1}$ 和 $\mathbf{e}_4^{r_1}$ 生成,这说明 $\mathbf{e}_i^{r_m}$ 保持了关于属性 r_m 的独立性,也说明了该模型语义可以在多层传播之后不受噪音影响。

3.2.2 用户属性兴趣建模

知识图谱中实体和属性之间的关系提供了丰富的语义信息,这些信息可以用来帮助推荐系统更好地理解用户兴趣。在推荐系统中,可以将用户对实体的行为看作是对该实体属性的偏好。但传统的协同过滤推荐模型通常使用平均池化方法来增强用户表示,这样就忽略了用户的个性偏好,难以实现个性化推荐^[27]。因此,本模块设计了一种注意力机制来对用户不同属性的兴趣进行建模。为每对用户 u 和属性 r_m 分配一个兴趣分数,并通过组合兴趣分数和交互项目来生成用户表示。

将不同的属性放置在相应的元素位置,利用相同的策略对用户嵌入 $\mathbf{e}_u$ 进行截断,如下所示:

$$\mathbf{e}_u = \mathbf{e}_u^{r_1} \parallel \mathbf{e}_u^{r_2} \parallel \dots \parallel \mathbf{e}_u^{r_M} \quad (20)$$

其中, $\mathbf{e}_u^{r_m} \in \mathbb{R}^{d^m}$ 是 $\mathbf{e}_u \in \mathbb{R}^D$ 的截断向量,用户 u 对属性 r_m 的兴趣分数被计算为:

$$f_{\text{att}}(u, r_m) = \sigma\left(\tau \frac{\frac{1}{|\mathcal{N}_u|} \sum_{i \in \mathcal{N}_u} \mathbf{e}_u^{r_m \top} \mathbf{e}_i^{r_m}}{\frac{1}{|\mathcal{J}|} \sum_{i \in \mathcal{J}} \mathbf{e}_u^{r_m \top} \mathbf{e}_i^{r_m}}\right) \quad (21)$$

其中, τ 是作为超参数的温度系数,如果用户 u 在选择项目时非常注重属性 r_m ,则用户感兴趣的项目和用户不感兴趣的项目相应位置的截断表示会是截然不同的。因此,两者的比值可以表示用户 u 对属性 r_m 感兴趣的程度。

在兴趣评分函数准备好后,需要将其与用户交互项目进行组合来生成用户嵌入表示。首先通过项目嵌入初步生成用户嵌入表示:

$$\mathbf{e}_u^a = \mathbf{e}_u + \parallel_{r_m \in \mathcal{R}} \left(\frac{1}{|\mathcal{N}_u|} \sum_{i \in \mathcal{N}_u} \mathbf{e}_i^{r_m} \right) \quad (22)$$

其中, $\parallel$ 表示拼接操作。基于上面得到的兴趣分数 $f_{\text{att}}(u, r_m)$,不难想到利用 $f_{\text{att}}(u, r_m)$ 去控制传递给用户 u 的属性

信息量。因此,用户 u 表示可以更新为:

$$\mathbf{e}_u^a = \mathbf{e}_u + \parallel_{r_m \in \mathcal{R}} \left(\frac{f_{\text{att}}(\mathbf{u}, r_m)}{|\mathcal{N}_u|} \sum_{i \in \mathcal{N}_u} \mathbf{e}_{r_m}^{r_m} \right) \quad (23)$$

3.3 预测模块

在关系模块和属性模块都生成了包含各自特性的用户表示和项目表示后,将两个模块的用户表示和项目表示分别进行组合,以生成最终的用户表示和项目表示,用于推荐预测。

根据式(13)和式(23),用户节点最终可以被表示为:

$$\mathbf{e}_u^* = \mathbf{e}_u^r \parallel \mathbf{e}_u^a \quad (24)$$

根据式(14)和式(19),项目节点最终可以被表示为:

$$\mathbf{e}_i^* = \mathbf{e}_i^r \parallel \mathbf{e}_i^a \quad (25)$$

最终,对用户和项目表示进行内积操作,以预测它们的匹配分数:

$$\hat{y}(u, i) = \mathbf{e}_u^{*T} \mathbf{e}_i^* \quad (26)$$

3.4 损失函数

为了优化推荐模型,选择贝叶斯个性化排序 (Bayesian Personalized Ranking, BPR) 损失^[28] 作为模型的损失函数。具体来说, BPR 损失假设被观察到的用户-项目交互应该比未观察到的用户-项目交互有更高的预测值:

$$\mathcal{L}_{\text{BPR}} = \sum_{(u, i, j) \in \mathcal{O}} -\ln \sigma(\hat{y}(u, i) - \hat{y}(u, j)) \quad (27)$$

其中, $\mathcal{O} = \{(u, i, j) \mid (u, i) \in \mathcal{O}^+, (u, j) \in \mathcal{O}^-\}$ 表示训练集, $\mathcal{O}^+$ 表示被观察到的用户-项目交互的正样本集合, $\mathcal{O}^-$ 代表未观察到的负样本集合; $\sigma()$ 是 sigmoid 函数。

在关系兴趣模块中还有一个保证关系兴趣独立性的模块,将其与 BPR 损失结合起来,生成最终 KGICR 模型的损失函数:

$$\mathcal{L} = \mathcal{L}_{\text{BPR}} + \lambda_1 \mathcal{L}_{\text{IND}} + \lambda_2 \parallel \Theta \parallel_2^2 \quad (28)$$

其中, Θ 是 KGICR 的模型参数集, λ_1 是控制独立性损失的超参数, λ_2 是 L_2 正则化的超参数。

4 实验结果及分析

为验证算法的有效性,将本文提出的 KGICR 模型与相关算法在基准数据集上进行比较分析。接下来将对实验所用数据集、实验设置、对比方法等展开介绍,并对实验结果进行分析。

4.1 数据集

为了评估 KGICR 模型的性能,在两个公用的数据集 Amazon-Book 和 Last. FM 上展开实验。Amazon-Book 数据集是一个由亚马逊公司提供的推荐系统数据集,包含了从 1996 年到 2014 年的亚马逊书籍销售数据。为了确保数据集的质量,同 KGAT 模型一样,只保留了至少有 10 个交互的用户和项目。Last. FM 数据集是一个音乐推荐系统研究领域的经典数据集,由 Last. fm 网站提供,包含了超过 100 万个用户和超过 17 万个艺术家,同时还有超过 200 万个用户对艺术家的听歌记录。本章采用了该数据集中时间戳从 2015 年 1 月到 2015 年 6 月的子集,并同样保留了至少有 10 个交互的用户和项目。这两个数据集的统计信息如表 1 所列。

表 1 数据集的基本信息

Table 1 Basic information of datasets

		Amazon-Book	Last. FM
用户-项目集	# 用户	70 679	23 566
	# 项目	24 915	48 123
	# 交互	846 434	3 034 796
知识图谱	# 实体	29 714	58 266
	# 关系	39	9
	# 三元组	686 516	464 567

除了用户-项目交互,还需要为每个数据集构建知识图谱。对于 Amazon-book 和 Last. FM 数据集,参考 KGAT 对数据集的设计,如果有可用的映射,根据标题将项目映射到知识图谱中对应的实体,特别是考虑与项目对齐的实体直接相关的三元组。常见的知识感知数据集仅考虑一阶邻域实体,而该设计方法还考虑了与项目相关的二阶邻域三元组。为了保证知识图谱质量,过滤掉出现频次较低的实体(即在两个数据集中都低于 10 个)并保留至少 50 个三元组中出现的关系来预处理知识图谱部分。

为了评估和比较不同模型的性能,同时防止模型在训练数据上过拟合而在测试数据上表现不佳,对于每个用户,其交互历史数据被分为训练集和测试集。随机选择其中 80% 作为训练集,剩余的 20% 作为测试集,并从训练集中随机选择 10% 作为验证集,以调整超参数。每个被观察到的用户-项目交互都作为正例,未被观察到有交互的项目作为负例,用于负抽样,即将其与用户之前没有消费过的一个消极项目配对。

4.2 参数设置

实验在 PyTorch 框架下实现了 KGICR 模型,模型的嵌入维度为 64。使用 Adam 优化器^[29] 优化模型,其中单次训练批量大小(batch size)固定为 1024。

本节对超参数应用网格搜索:学习率在 $\{10^{-4}, 10^{-3}, 10^{-2}\}$ 之间进行调整,附加约束的系数(如所有方法中的 L_2 正则化、关系兴趣建模模块中的独立性建模等)在 $\{10^{-5}, 10^{-4}, \dots, 10^{-1}\}$ 范围内进行搜索,图卷积的层数在 $\{1, 2, 3\}$ 中进行调整,邻居集的大小在 $\{1, 2, 4, 8, 16, 32\}$ 的范围内。此外,使用 Xavier^[30] 对模型参数进行初始化。

4.3 对比方法

为了更好地评估文中所提出的模型的有效性,将其与 7 个相关方法进行比较,其中包括一个非知识图谱推荐模型和多个基于知识图谱的推荐模型。

1) NFM^[31]: He 等将因子分解机 (Factor Machine, FM) 中的二阶交叉项(即特征之间的内积)替换为一个全连接的神经网络层,对用户和物品的特征进行非线性建模。

2) MCRec^[32]: Hu 等提出的一种基于元路径的推荐模型,通过利用用户和物品之间的元路径关系,来学习二者之间更复杂和更深层次的关系,从而提高推荐的准确性。

3) RippleNet^[33]: Wang 等在知识图谱上传播用户的偏好,并以该用户为根构建路径。该模型是一种带有“记忆”特点的神经网络模型,用于增强用户表示,提升推荐质量。

4) CFKG^[34]: 该模型使用 TransE 方法在一个包含用户、项目、实体和关系的协同知识图上进行推荐任务,通过预测(用户,交互,项目)三元组的合理性来实现个性化推荐。

5)CKE^[35]:该模型采用 TransR 方法从知识图谱中学习
知识信息,并将信息注入到项目嵌入表示中。其中,知识图谱
关系仅用作监督信号,对实体的表示进行正则化。

6)KGNN-LS^[36]:为了生成关于用户的特定项目表示,该
模型利用图神经网络和标签平滑正则化方法增强了项目嵌入
表示,并考虑了用户对知识图谱中关系的特定偏好。

7)KGAT^[8]:Wang 等将图注意力网络应用于知识图谱和
用户-项目图组合的协同知识图上,能够明确地构建用户、项
目和属性之间的高阶关系,并以端到端的方式将协作信息和
知识信息编码到用户和项目。

4.4 实验结果及分析

为了验证 KGICR 模型能够提升推荐性能,以及捕获用
户兴趣,进而为用户进行个性化推荐,在两个真实数据集上进
行了实验,并与非知识图谱推荐以及知识图谱推荐基线模型
进行了对比,实验结果如表 2 所列。

表 2 KGICR 与基线模型的对比结果

	Amazon-Book		Last. FM	
	Recall@20	NDCG@20	Recall@20	NDCG@20
NFM	0.1348	0.0791	0.0784	0.1179
MCRec	0.1135	0.0764	0.0702	0.1082
RippleNet	0.1359	0.0860	0.0805	0.1243
CFKG	0.1306	0.0768	0.0722	0.1130
CKE	0.1344	0.0782	0.0734	0.1149
KGNN-LS	0.1362	0.0893	0.0805	0.1284
KGAT	0.1487	0.0943	0.0876	0.1316
KGICR(Ours)	0.1541	0.0983	0.0902	0.1342

观察表 2 可以发现,KGICR 在两个数据集都具有最好的
性能。在 Amazon-Book 和 Last. FM 两个数据集上,其 Re-
call@20 较最优的基线算法分别提升了 3.6%和 4.2%;ND-
CG@20 分别提升了 2.9%和 2.0%。实验结果表明,利用知
识图谱中关系和属性信息捕获用户兴趣,并利用图卷积网络
对用户兴趣进行传播,可以细粒度地对用户兴趣进行捕捉,更
好地学习用户和项目的最终表示,以获得更好的推荐结果。
仔细观察可以发现,KGICR 在 Amazon-Book 数据集上的改
进效果要比在 Last. FM 数据集上的改进效果更好,这是因为
Amazon-Book 对应的知识图谱比 Last. FM 的提供了更加密
集且丰富的信息。此外,Last. FM 对应的知识图谱大多数三
元组仅仅保持一阶连通性,而 Amazon-Book 对应的知识图谱
包含着大量具有高阶连通性的三元组,这表明 KGICR 更善
于利用高阶邻域信息。

在基线方法中,大部分的知识图谱推荐方法的推荐性能
优于 NFM 模型,这表明了知识图谱这种辅助信息对于推荐
系统的重要性。但其中 CFKG 和 CKE 模型的推荐性能比
NFM 模型稍差一些,这表明基于知识图谱嵌入的正则化方法
可能无法充分利用知识图谱中的项目属性关系等信息。在所
有方法中,基于路径的方法 MCRec 的推荐性能最差,这很可
能是因为 MCRec 的推荐性能在很大程度上取决于元路径的
质量,而元路径需要研究者具有丰富的相关领域知识去人工
定义。此外,基于图神经网络的方法的知识图谱推荐模型
KGNN-LS 和 KGAT 在两个数据集上的表现优于其他基线
模型,这表明了对高阶邻域信息进行建模的重要性,因为该类

模型主要通过使用知识图谱中节点的多跳邻域来增强用户和
项目的嵌入表示。

4.5 消融实验

为了验证各个模块的有效性,本节对 KGICR 模型进行
了消融实验,通过消除 KGICR 不同模块来探索该模块对提
升模型推荐的贡献程度。本节将 KGICR 模型的两个变体分
别定义为缺失关系兴趣模块的 KGICR(w/o R)和缺失属性兴
趣模块的 KGICR(w/o A)。消融实验结果如表 3 所列。

表 3 消融实验
Table 3 Ablation study

	Amazon-Book		Last. FM	
	Recall@20	NDCG@20	Recall@20	NDCG@20
KGICR(w/o R)	0.1481	0.0935	0.0874	0.1306
KGICR(w/o A)	0.1497	0.0942	0.0880	0.1313
KGICR	0.1541	0.0983	0.0902	0.1342

观察消融实验结果可以发现,去除关系兴趣模块或属性
兴趣模块会降低 KGICR 模型的推荐性能。这说明在知识图
谱推荐任务中,知识图谱中的关系信息和属性信息都对细化
用户兴趣、增强用户和项目表示,以及提升模型的推荐性能有
着显著的贡献。此外,大多数情况下,KGICR(w/o R)相对于
KGICR(w/o A)表现较差,这可能是因为在知识图谱推荐任
务中,部分属性信息可以通过与其连接的项目节点被传递到
用户节点,而关系信息则被大部分知识图谱推荐方法忽略,这
也证明了关系兴趣模块对细粒度地捕捉用户兴趣的可行性和
有效性。总之,本节的消融实验进一步证明了同时收集来自
知识图谱中的关系信息和属性信息对捕捉用户兴趣和提高推
荐性能的重要性。

4.6 GCN 层数分析

为了进一步探索 KGICR 的最佳性能,考虑改变关系兴
趣模块和属性兴趣模块的消息传播层(即 GCN 层)的数量。
通常来说,堆叠多个图卷积层能够将高阶邻域所携带的信息
集成到节点表示中,但是堆叠太多层又可能会使节点聚合了
许多噪声信息,导致推荐性能下降和产生过拟合现象。本节
将 KGICR 模型中消息传播层的数量 L 设置在 $\{1,2,3,4\}$
的范围内,在两个数据集上的实验结果如表 4 所列。

表 4 不同 GCN 层数的影响
Table 4 Influence of different GCN layers

	Amazon-Book		Last. FM	
	Recall@20	NDCG@20	Recall@20	NDCG@20
KGICR($L=1$)	0.1476	0.0937	0.0881	0.1336
KGICR($L=2$)	0.1502	0.0964	0.0908	0.1351
KGICR($L=3$)	0.1541	0.0983	0.0902	0.1342
KGICR($L=4$)	0.1513	0.0972	0.0891	0.1335

观察表 4 可以发现,当 KGICR 模型有 2 层或 3 层消息传
播层时,KGICR 模型拥有较好的推荐性能。具体来说,当
 $L=2$ 或 $L=3$ 时,相较于单层消息传播层,模型的推荐性能有
了显著提升。这是因为堆叠更多的卷积层可以探索一些由知
识图谱三元组连接的更多相关项目,并加深模型对用户兴趣
的理解。此外,有许多与用户兴趣相关的信息是从更多的关
系路径和属性实体派生出来的,学习这些信息有助于模型更
好地分析用户对项目的偏好。相较于两层消息传播层,当

$L=3$ 时,KGICR 模型在 Last.FM 数据集上的推荐性能略有下降,这很可能是因为 Last.FM 对应的知识图谱中有大量一阶连接的三元组,导致模型难以学习知识图谱中的高阶信息。当 $L=4$ 时,模型性能全面下降,这很可能是因为过多的卷积层导致节点学习到了过多噪声信息或由于过拟合所导致的。考虑到 KGICR 模型的通用性,本节选取包含 3 层消息传播层的 KGICR 模型(即 $L=3$ 时)作为最优模型与其他基线进行比较。

结束语 本文提出了一种基于知识图谱的兴趣捕捉推荐算法 KGICR,用于个性化推荐任务。KGICR 包含关系兴趣模块和属性兴趣模块。关系兴趣模块将用户兴趣表示为知识图谱中关系嵌入的组合,通过注意力机制将用户的个性化兴趣向量化,并引入了一个距离相关的独立性模块,以使用户的不同兴趣彼此独立。项目嵌入考虑关系信息及其邻域的实体信息,利用图卷积网络学习高阶邻域信息,以增强用户和项目表示。属性兴趣模块对项目的属性特征和原始表示进行拼接,以生成包含属性信息的项目表示。用户表示生成采用与项目表示类似的策略,为了区分用户对不同属性的个性化兴趣,设计了一个属性兴趣注意力机制为每个属性分配一个兴趣分数,并通过图卷积网络学习高阶邻域属性信息,增强用户和项目的表示。将两个模块得到的用户和项目表示进行拼接,生成用户和项目的最终表示,用于预测。在两个基准数据集上进行实验验证,实验结果验证了 KGICR 有助于提升个性化推荐任务的性能。

参 考 文 献

- [1] KUMAR P,THAKUR R S.Recommendation system techniques and related issues;a survey[J]. International Journal of Information Technology,2018,10:495-501.
- [2] NAGARNAIK P,THOMAS A.Survey on recommendation system methods[C]//2015 2nd International Conference on Electronics and Communication Systems (ICECS). India: IEEE Press,2015:1603-1608.
- [3] WU L,HE X,WANG X,et al.A survey on accuracy-oriented neural recommendation:From collaborative filtering to information-rich recommendation[J]. arXiv:2104.13030,2021.
- [4] JAVED U,SHAUKAT K,HAMMED I A,et al.A review of content-based and context-based recommendation systems[J]. International Journal of Emerging Technologies in Learning (iJET),2021,16(3):274-306.
- [5] WALEK B,FOJTIK V.A hybrid recommender system for recommending relevant movies using an expert system[J]. Expert Systems with Applications,2020,158:113452.
- [6] WEI Y,WANG X,LI Q,et al.Contrastive learning for cold-start recommendation[C]//Proceedings of the 29th ACM International Conference on Multimedia. New York:Association for Computing Machinery,2021:5382-5390.
- [7] ZHOU J,CUI G,HU S,et al.Graph neural networks:A review of methods and applications[J]. AI open,2020,1:57-81.
- [8] WANG X,HE X,CAO Y,et al.Kgat:Knowledge graph attention network for recommendation[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:Association for Computing Machinery,2019:950-958.
- [9] GOLDBER D,NICHOL D,OKI B M,et al.Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM,1992,35(12):61-70.
- [10] COVINGTON P,ADAMS J,SARGIN E.Deep neural networks for youtube recommendations[C]//Proceedings of the 10th ACM Conference on Recommender Systems. New York:Association for Computing Machinery,2016:191-198.
- [11] CHENG H T,KOC L,HARMSSEN J,et al.Wide & deep learning for recommender systems[C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. New York:Association for Computing Machinery,2016:7-10.
- [12] ZHOU G,ZHU X,SONG C,et al.Deep interest network for click-through rate prediction[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York:Association for Computing Machinery,2018:1059-1068.
- [13] DONKERS T,LOEPP B,ZIEGLER J.Sequential user-based recurrent neural network recommendations[C]//Proceedings of the eleventh ACM Conference on Recommender Systems. New York:Association for Computing Machinery,2017:152-160.
- [14] WU S,TANG Y,ZHU Y,et al.Session-based recommendation with graph neural networks[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York:Association for Computing Machinery,2019:346-353.
- [15] HE X,DENG K,WANG X,et al.Lightgcn:Simplifying and powering graph convolution network for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Xi'an: Virtual Event,2020:639-648.
- [16] WANG X,HE X,WANG M,et al.Neural graph collaborative filtering[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York:Association for Computing Machinery,2019:165-174.
- [17] LIN Z,TIAN C,HOU Y,et al.Improving graph collaborative filtering with neighborhood-enriched contrastive learning[C]//Proceedings of the ACM Web Conference 2022. New York:Association for Computing Machinery,2022:2320-2329.
- [18] WANG H,ZHANG F,XIE X,et al.DKN:Deep knowledge-aware network for news recommendation[C]//Proceedings of the 2018 World Wide Web Conference. Lyon:Association for Computing Machinery,2018:1835-1844.
- [19] CAO Y,WANG X,HE X,et al.Unifying knowledge graph learning and recommendation:Towards a better understanding of user preferences[C]//The World Wide Web Conference. San Francisco:Association for Computing Machinery,2019:151-161.
- [20] HUANG X,FANG Q,QIAN S,et al.Explainable interaction-driven user modeling over knowledge graph for sequential recommendation[C]//Proceedings of the 27th ACM International Conference on Multimedia. New York:Association for Computing Machinery,2019:548-556.

[21] HU B,SHI C,ZHAO W X,et al. Leveraging meta-path based context for top-n recommendation with a neural co-attention model[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: Association for Computing Machinery, 2018: 1531-1540.

[22] WANG H,ZHANG F,WANG J,et al. Ripplenet: Propagating user preferences on the knowledge graph for recommender systems[C] // Proceedings of the 27th ACM International Conference on Information and Knowledge Management. Torino: Association for Computing Machinery, 2018: 417-426.

[23] WANG H,ZHAO M,XIE X,et al. Knowledge graph convolutional networks for recommender systems[C] // The World Wide Web Conference. San Francisco: Association for Computing Machinery, 2019: 3307-3313.

[24] XU J,LANGE K. A proximal distance algorithm for likelihood-based sparse covariance estimation [J]. Biometrika, 2022, 109(4):1047-1066.

[25] SACENTI J A P,FILETO R,WILLRICH R. Knowledge graph summarization impacts on movie recommendations[J]. Journal of Intelligent Information Systems, 2022, 58(1): 43-66.

[26] XU H,XU X J,MENG F J. Knowledge graph-assisted multi-task feature-based course recommendation algorithm [J]. Computer Engineering and Applications, 2021, 57(21): 132-139.

[27] XU B,YI P Y,WANG J C,et al. High-order collaborative filtering recommendation system based on knowledge graph embedding[J]. Computer Science, 2021, 48(S2): 244-250.

[28] PEI H,LIU X,HUANG X,et al. A personalized recommendation method under the cloud platform based on users' long-term preferences and instant interests[J]. Advanced Engineering Informatics, 2022, 54: 101763.

[29] DING M,DENG Z,HUANG Z,et al. Recovery of polyimide waste film by mechanical method to improve the heat fade resistance of BPR matrix friction composites[J]. Wear, 2022, 502: 204398.

[30] ZHANG Z. Improved adam optimizer for deep neural networks [C] // 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS). Banff: Association for Computing Machinery, 2018: 1-2.

[31] GHATAK A. Initialization of Network Parameters [J]. Deep Learning with R, 2019: 87-102.

[32] HE X,CHUA T S. Neural factorization machines for sparse predictive analytics [C] // Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. Japan: Association for Computing Machinery, 2017: 355-364.

[33] HU B,SHI C,ZHAO W X,et al. Leveraging meta-path based context for top-n recommendation with a neural co-attention model[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: Association for Computing Machinery, 2018: 1531-1540.

[34] AI Q,AZIZI V,CHEN X,et al. Learning heterogeneous knowledge base embeddings for explainable recommendation[J]. Algorithms, 2018, 11(9): 137.

[35] ZHANG F,YUAN N J,LIAN D,et al. Collaborative knowledge base embedding for recommender systems[C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: Association for Computing Machinery, 2016: 353-362.

[36] WANG H,ZHANG F,ZHANG M,et al. Knowledge-aware graph neural networks with label smoothness regularization for recommender systems [C] // Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: Association for Computing Machinery, 2019: 968-977.



JIN Yu, born in 1996, postgraduate. His main research interest is recommendation algorithm.



CHEN Hongmei, born in 1971, Ph. D, professor, Ph.D supervisor, is a member of CCF (No. 19214M). Her main research interests include intelligent information processing, pattern recognition, etc.

(责任编辑:柯颖)