

融合知识图谱与图片特征的推荐模型

陈乔松^① 郭傲东^① 杜雨露^{*①} 张怡文^② 朱越^③

^①(重庆邮电大学计算机科学与技术学院 重庆 400065)

^②(安徽新华学院信息工程学院 合肥 230000)

^③(河南农业大学信息与管理科学学院 郑州 450046)

摘要: 目前知识图谱研究主要面向信息检索、自然语言理解等领域,在推荐系统中融合知识图谱成为推荐领域学者广泛关注的问题。为了解决单一知识图谱忽略的丰富知识信息,该文对知识图谱进行多模态扩展,并提出一种融合知识图谱与图片特征的推荐模型(KG-I)。不同于其他基于知识图谱的推荐算法,该方法增加视觉嵌入、知识嵌入和结构嵌入去挖掘用户项目之间的隐式反馈信息。该模型利用深度游走模型(Deep Walk)捕获空间结构的方法和波纹网络模型(RippleNet)挖掘知识图谱的知识表达的思想,并且考虑图片对用户偏好的影响,有效地将信息进行融合,并在真实数据集上与其他模型实验比较,研究多种特征的影响,分析不同稀疏度数据下的表现。结果表明,融合知识图谱与图片特征的个性化推荐模型完全优于其他的对比算法并且有效缓解数据稀疏情况。

关键词: 图像处理; 知识图谱; 数据融合; 多模态

中图分类号: TN911.73; TP311

文献标识码: A

文章编号: 1009-5896(2022)05-1723-11

DOI: [10.11999/JEIT210230](https://doi.org/10.11999/JEIT210230)

Recommendation Model by Integrating Knowledge Graph and Image Features

CHEN Qiaosong^① GUO Aodong^① DU Yulu^① ZHANG Yiwen^② ZHU Yue^③

^①(School of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

^②(College of Information Engineering, Anhui Xinhua University, Hefei 230000, China)

^③(School of Information and Management Science, Henan Agricultural University, Zhengzhou 450046, China)

Abstract: At present, the study of knowledge graph focuses mainly on information retrieval, natural language understanding and other fields. Integrating knowledge graph with recommendation system has been concerned by scholars in the field. In order to mine the rich information ignored in knowledge graph, the knowledge graph is extended to multimodal and a recommendation model that incorporates Knowledge Graph with Image (KG-I) features is proposed. Different from other recommendation algorithms, visual embedding, knowledge embedding and structure embedding are combined to capture implicit feedback between user-items. The Deep Walk is used to capture the spatial structure and the ideal of RippleNet to retain the semantic features of knowledge graph, and the effect of images on preference is considered to integrate information. Compared with other models on the real data set, the influence of various features is studied, and the performance of different sparsity data is analyzed. The results show that the personalized recommendation model based on knowledge graph and image features outperforms other algorithms and the data sparsity can be alleviated.

Key words: Image processing; Knowledge graph; Data fusion; Multimodality

收稿日期: 2021-03-22; 改回日期: 2022-01-03; 网络出版: 2022-01-27

*通信作者: 杜雨露 duy1@cqupt.edu.cn

基金项目: 重庆邮电大学社科项目(K2021-114)

Foundation Item: The Social Science Project of Chongqing University of Posts and Telecommunications (K2021-114)

1 引言

目前推荐系统中相对核心推荐算法大致可以分为基于内容的推荐^[1]、协同过滤推荐^[2]、基于关联规则的推荐^[3]以及混合推荐^[4]。针对广泛应用的协同过滤推荐,该方法依赖用户的历史偏好信息,当用户行为数据越稀疏时,推荐的精确度越低;同时,还存在着新用户和新商品的冷启动等问题。

为了解决这些问题,研究者尝试将社交网络、用户项目属性、图片文字等信息引入推荐系统。深度学习算法^[5]能够有效地挖掘辅助信息潜在的用户兴趣偏好,研究者开始将传统推荐算法与深度学习相结合^[6],例如深度兴趣网络的点击率预测^[7]和改进递归神经网络的会话推荐^[8]等。

近几年,知识图谱成为一种新起的辅助信息,知识图谱更多地挖掘现实中存在的交互联系。这种融合知识图谱的推荐能够深层次地发现用户的兴趣,避免单一类型的推荐结果,同时知识图谱也可以对推荐结果进行解释,增强用户对推荐系统的信任。基于传统知识图谱的推荐系统研究分为两类,一类采用的是基于知识图谱特征学习方法^[9,10],例如,高阶邻域混合模型(MixHop)^[11]通过不同距离之间的特征反复学习挖掘特征关系。深度知识感知网络(Deep Knowledge-aware Network, DKN)^[12]通过提取文本构建知识图谱,将新闻的词向量与知识图谱的实体融合。这些模型更多的关注于知识图谱内部的语义信息,忽略了知识图谱的空间结构特征;另一类采用的是基于固定路径数据^[13,14]的方法,例如,元图融合推荐模型(Meta-Graph based Recommendation Fusion, FMG)^[13]通过设定特定路径挖掘实体之间的潜在关系,直观地利用网络结构但是路径较为固定。文献^[14]提出一种基于元图的融合注意力机制的网络,通过注意机制从固定路径中挖掘交互信息来训练模型构建推荐器进行推荐。该类方法通过设定固定的连接方式直观地捕获知识图谱地网络结构,但是需要手动设定元路径且丢失大量的语义信息。

最近,对于多模态知识图谱的特征组合成为研究趋势。多模态知识图谱通过图片、文本等信息去调整传统知识图谱中的语义关系。与传统开源知识图谱的数据相同,维基数据(Wikidata)、图像链接数据集(Images Gpedia, IMGpedia)等多模态数据库仍旧存在具体场景应用问题。多模态知识图谱的不同数据信息一方面解决了单一知识图谱对用户偏好挖掘的局限性,另一方面也是构建多模态知识图谱的极大挑战。多模态知识图谱的构成一定程度地解决单一知识图谱中过于相似实体间的歧义信息,极大程度地确保实体信息挖掘的准确性。

针对以上问题及推荐系统中数据稀疏问题,本文提出一种融合知识图谱与图片特征的推荐模型。该模型利用深度游走模型(Deep Walk)^[15]捕获空间结构的方法和波纹网络模型(RippleNet)^[9]的思想同时挖掘知识图谱的空间结构和知识表达,并且考虑图片对用户偏好的影响,扩展知识图谱模态,有效地将这些信息进行混合,从而进一步提高了推荐精度。本文的贡献主要包括以下几点。

(1) 与现有的研究不同,本文提出融合知识图谱语义特征、空间结构信息以及图片特征的推荐模型(KG-I)。将知识图谱结构嵌入、知识嵌入和视觉嵌入作为不同模态输入,并保持各模态间的对应关系,去挖掘用户-项目之间的潜在信息,以此提高推荐算法的性能;

(2) 本文基于知识图谱挖掘了其结构信息和知识信息相关的两种向量表示,基于图片特征构建了用户兴趣度矩阵。设计融合策略,以用户对项目的隐式反馈作为衔接,对3种不同的嵌入表示更好的融合;最后,结合L2正则优化和梯度下降对特征概率进行限制;

(3) 在真实的数据集上进行了一系列的实验来验证模型的推荐效果,包括与现有模型的效果比较、研究多种特征对于推荐效果的影响、研究模型在不同稀疏度数据子集的表现。结果表明,这种融合知识图谱与图片特征的个性化推荐模型完全优于对比算法。

2 相关工作

2.1 知识图谱

知识图谱(Knowledge Graph)^[12]具有强大的语义表达能力,本质上是语义网络的知识库,具体地说是一种表达语义的多关系图。从最初的优化Google搜索引擎,到现在的自然语言理解、聊天机器人、问答系统、可视化知识表现等都与知识图谱技术相关。近年,知识图谱在推荐领域的热度也不断上升,较多的推荐领域学者致力于构建商品、电影、音乐相关的知识图谱,从中挖掘出用户的潜在兴趣偏好,分析知识图谱对推荐系统性能的影响。

2.2 知识图谱与推荐系统

知识图谱运用于推荐领域成为热门研究,一方面知识图谱补全了推荐系统项目信息的完整性,提供了更多与项目相关的信息;另一方面知识图谱模拟了实际用户对项目的兴趣路径。因此,利用知识图谱的推荐系统方法分为两类,基于知识图谱特征学习方法和基于固定路径数据的方法。基于知识图谱特征学习方法^[16,17]主要通过提取文本构建知识图谱,将项目与知识图谱中实体进行融合,然后利用传统

的推荐模型进行训练，如协同知识嵌入(Collaborative Knowledge base Embedding, CKE)^[18]、深度知识感知网络(Deep Knowledge-aware Network, DKN)^[12]等，这些特征更多利用项目之间的丰富的语义信息。基于固定路径数据^[13,14]的方法主要通过设定特定路径挖掘实体之间的潜在关系，利用网络结构来挖掘项目之间的潜在关系，如元图融合推荐模型(Meta-Graph based recommendation Fusion, FMG)^[14]、个性化实体推荐模型(Personalized Entity Recommendation, PER)^[19]等，直观地捕获知识图谱的网络结构。

多模态知识图谱与传统的知识图谱最主要的区别主要体现在图谱中的实体通过不同模态进行刻画，形成一种多模态的语义关联，因此需要注意不同模态下的数据对应关系。多模态知识图谱运用于推荐系统主要侧重于特征和实体的两种方式：基于特征的方式是将不同模态信息直接视为实体的辅助信息，如文献^[20]提出的基于多模式翻译模型，该模型在知识图谱的3元组数据上加入视觉和语言信息，设计融合函数使用特征；基于实体的方式是将不同类别的信息视作结构化的知识关系3元组，如多模态知识图谱嵌入(Multimodal Knowledge Base Embeddings, MKBE)^[21]将不同数据与关系模型结

合去学习实体的关系的嵌入，提出新型多模填补模型生成缺失的多模数据。

3 融合知识图谱与图片特征的推荐模型

本文通过深度游走^[15]算法和RippleNet^[9]模型的思想，可以自主挖掘知识图谱的知识信息和结构信息，不需要手动设置路径，并在此基础上引入图片特征来提升推荐系统的性能。利用知识图谱 G 与用户评分列表 L 作为模型输入，结合项目的图片特征，从而输出用户点击项目的预测概率。

融合知识图谱与图片信息的推荐模型(integrating Knowledge Graph and Image features, KG-I)结构如图1所示，其中上半部分包含知识图谱 G 与图片构成的多模态知识图谱和视觉嵌入方法，下半部分包含多模态知识图谱的结构嵌入和知识嵌入方法。如图1结构模块所示，结构嵌入中利用深度游走思想获取知识图谱的空间结构特征表示；如图1语义模块所示，知识嵌入中将头尾节点与关系组建3元组表示知识图谱的语义关系，获取用户的扩散偏好集合，对知识图谱的语义特征表示；如图1图片模块所示，视觉嵌入挖掘知识图谱实体的图片特征。最终对3种不同的嵌入表示进行融合，输出用户点击项目的预测概率。

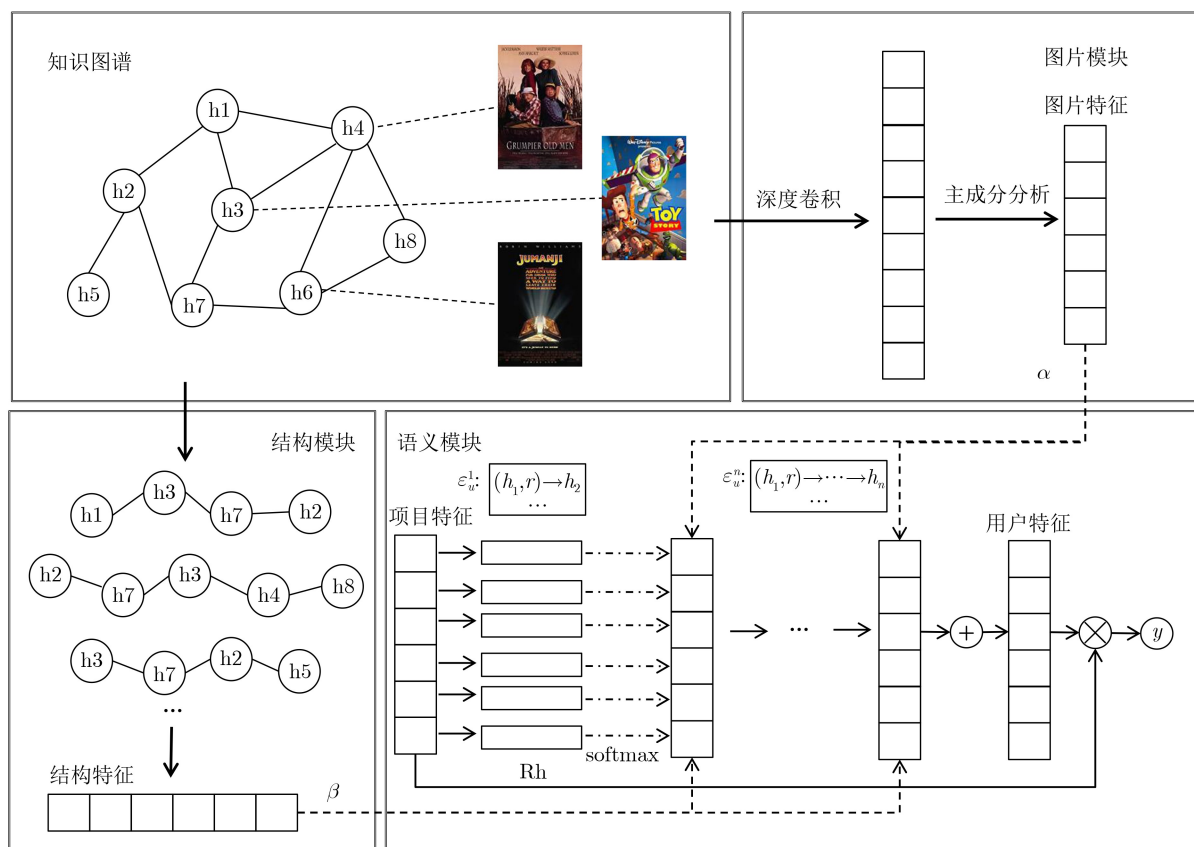


图 1 KG-I框架图

本文的推荐系统以点击率预测为目标进行训练,同时根据点击率排序进行Top-N列表推荐。考虑知识图谱和推荐算法以及融合特征进行联合学习,所以模型的损失函数如式(1)所示

$$\text{Loss} = L_{\text{pre}} + \lambda_1 L_{\text{KG}} + \lambda_2 \|\Theta\|_2^2 \quad (1)$$

其中, L_{pre} 为预测损失函数, L_{KG} 为知识图谱特征学习损失函数, Θ 是模型融合特征中的参数集合,采用 L_2 正则化对模型参数进行限制防止模型过度拟合,以及随机梯度下降法来优化损失函数。

3.1 结构特征学习

知识图谱类似于一种项目信息网络,知识图谱的结构特征与普通信息网络相同,可以通过向量或向量集的形式获取知识图谱的拓扑结构,保留知识图谱的结构信息。本文利用Deep Walk^[15]的思想对知识图谱的节点进行向量表示,在知识图谱上设计一个以节点 v_i 为初始起点的随机游走路径,生成随机序列 \mathbf{W}_{v_i} ($\mathbf{W}_{v_i}^1, \mathbf{W}_{v_i}^2, \dots, \mathbf{W}_{v_i}^k$),其中 $\mathbf{W}_{v_i}^k$ 是以 v_i 为初始节点生成随机路径上的实体节点。通过随机游走不断迭代更新学习使得随机序列从局部覆盖整个知识图谱,从而表达整个图谱的空间结构。如图1结构模块所示,从知识图谱 G 的某实体 h 出发,采样此实体 h 随机移动到其他实体 h 的游走路径,得到每个实体 h 的随机序列,根据深度游走的节点向量化表示,获得图谱的空间结构的特征嵌入。

结构特征学习模块的目标是获取知识图谱中实体节点在知识图谱中位置的向量维度映射,利用知识图谱邻近节点的依赖性实现知识图谱结构特征表示。通过深度游走方法无监督地捕获知识图谱拓扑结构信息,整个知识图谱的实体由各个实体对应的向量表示反映整个网络的结构特征。适当规模的向量特征表示通用于任何分类算法或者集成于其他机器学习算法。

3.2 知识特征学习

知识图谱与普通网络结构图不同,推荐项目的知识图谱涵盖项目大量的隐藏知识语义信息。知识图谱中每一条复杂连接在实际场景下均可以进行有效的翻译,例如用户对某项目的行为通过路径传递至另一项目,可以根据3元组(头节点、关系、尾节点)表示链路的语义特征,所有的尾节点作为头节点和关系的翻译结果反映用户的潜在兴趣偏好。而这种传递随着链路的增加带来更多的噪声数据使用户的潜在偏好受到影响。合适的链路长度不仅需要挖掘用户在知识图谱中的潜在偏好同时也要满足项目能够与远端项目保有联系。

知识图谱中路径长短对用户兴趣的影响较早的在RippleNet^[9]中被验证,其中指出用户潜在偏好强

度随着路径长度的增加而减小,符合波纹逐渐衰减原理。

给定用户交互矩阵 \mathbf{Y} 和知识图谱 G 用户 u 的 k 步的项目相关偏好集合定义为 $\varepsilon_u^k = \{t | (h, r, t) \in G \text{ and } h \in \varepsilon_u^{k-1}\}, k = 1, 2, 3$ 。当 $k = 0$ 时, $\varepsilon_u^0 = Y_u = \{y | y_{uv} = 1\}$ 是用户初始评分集合。随着链路长度的增加,逐步往外扩散,最后获得扩散偏好集 $\varepsilon_u = \varepsilon_u^0 \vee \varepsilon_u^1 \vee \varepsilon_u^2 \dots \varepsilon_u^n$,其中 n 为链路长度。

在知识图谱中每个项目 v 有一个与之相关联的向量表示。如图1语义模块所示,根据用户项目交互矩阵和用户偏好扩散集合中每一个3元组分配相关性概率式(2)

$$p_i = \text{softmax}(\mathbf{v}^T \mathbf{R}_i \mathbf{h}_i) = \frac{\exp(\mathbf{v}^T \mathbf{R}_i \mathbf{h}_i)}{\sum_{(h,r,t) \in \varepsilon_u} \exp(\mathbf{v}^T \mathbf{R}_i \mathbf{h}_i)} \quad (2)$$

其中, $\mathbf{R}_i \in \mathbb{R}^{d \times d}$, $\mathbf{h}_i \in \mathbb{R}^d$ 分别是图谱中关系和实体的向量表示。 p_i 可以表示为用户对项目 v 表示兴趣时,项目 v 在知识图谱与之相连的实体集中第 i 个实体 h_i 的相似概率。

为了减少计算开销,每个用户扩散偏好集的大小相同。后续实验会讨论扩散偏好集的大小以及链路长度对推荐结果的影响。

3.3 图片特征提取

用户选择项目的兴趣来源主要包括朋友的推荐、与之前项目类似的物品等途径,同时图片信息可以给用户带来最直接的感官刺激。因此,在一定的程度上项目图片特征对用户的选择有着隐式影响。

本文设计图片特征模块,如图1图片模块所示,该模块挖掘项目图片的潜在特征,后续与知识图谱分解后的结构特征和语义特征相融合重构项目特征,缓解传统协同过滤算法中的数据稀疏性问题。具体使用图像卷积神经网络(Visual Geometry Group, VGG16)^[22]框架挖掘项目图片特征的流程如图2所示。

使用VGG16框架卷积图片数据获得高维海报特征数据。较大的数据组成面临着高难度的运算复杂度,因此选择主成分分析算法(Principal Component Analysis, PCA)^[23]在保留图片数据的特征的同时降低数据维度,降低后续运算和时间复杂度。根据主成分公式获得PCA处理后的低维图片特征数据与分解后的知识图谱特征融合。当项目不存在图片时,使用 $\mathbf{0}$ 向量作为项目的图片特征,使得当前项目不参与图片特征的融合。

3.4 知识图谱与图片特征的融合策略

为了以更细粒度的方式模拟用户与项目之间的



图 2 VGG16框架图

交互，提出了一种知识图谱语义特征、结构特征和图片特征的融合策略去挖掘用户潜在兴趣偏好。

该方法在获得实体节点的结构特征、语义特征和图片特征后，考虑各种特征之间差异较大，为了有效融合各种数据源的特征使得每个用户对知识图谱的响应程度更客观更综合，对特征数据源设计关系权重进行加权融合，计算用户 u 在知识图谱不同长度链路下的实体响应作为用户嵌入，如式(3)所示

$$u = o_u^1 + o_u^2 + \dots + o_u^n \quad (3)$$

其中， o_u^n 是用户 u 对偏好扩散集 ε_u^n 的实体响应。用户 u 在当前链路下的实体响应是在节点知识语义特征的基础上，将该节点结构特征和图片特征进行加权融合，如式(4)所示

$$o_u^n = \sum_{(h_i, r_i, t_i) \in \varepsilon_u^n} (p_i t_i + \alpha_i S_i + \beta_i F_i) \quad (4)$$

其中， t_i 是实体 h_i 通过关系 r_i 连接的实体， p_i 是通过语义模块计算得到的语义相似度， α_i, β_i 分别是实体 t_i 对应的结构特征 S_i 和图片特征 F_i 的权重。

加权特征融合技术将结构特征和图片特征融入知识图谱的知识语义中，使得不同特征之间不再独立，同时根据梯度下降算法，最小化损失函数，寻找最优融合权重。加权融合方法使每种特征信息更

加精简有效，减少冗余信息，避免高维度特征带来的速度下降及多种信息不相容的问题。

最后，用户嵌入和项目嵌入组合以输出预测的单击概率如式(5)所示

$$y_{uv} = \sigma(u^T v) \quad (5)$$

其中， σ 表示sigmoid函数 $f(x) = \frac{1}{1 + e^{-x}}$ 。

通过最小化真实值和预测值间的交叉熵损失来训练模型，如式(6)所示

$$L_{pre} = - \sum_{i=1}^{|U|} (q_i \lg(y_i) + (1 - q_i) \lg(1 - y_i)) \quad (6)$$

其中， y 为预测概率分布， q 为真实概率分布。最终考虑知识图谱以及融合特征进行联合学习，模型损失函数如式(7)所示

$$\begin{aligned} Loss &= L_{pre} + \lambda_1 L_{KG} + \lambda_2 \|\Theta\|_2^2 \\ &= - \sum_{i=1}^{|U|} (q_i \lg(y_i) + (1 - q_i) \lg(1 - y_i)) \\ &\quad + \lambda_1 \sum_{r \in R} \|I_r - E^T R E\|_2^2 \\ &\quad + \lambda_2 \left(\|V\|_2^2 + \|E\|_2^2 + \sum_{r \in R} \|R\|_2^2 + \|\alpha\|_2^2 + \|\beta\|_2^2 \right) \end{aligned} \quad (7)$$

其中, V, E, R 分别为项目和知识图谱实体与关系的向量表示。 I_r 是项目在关系 r 下的向量表示。 α, β 分别表示知识图谱结构特征和图片特征的权重向量。损失函数由3项组成, 第1项表示预测概率与真实值之间的交叉熵损失函数, 第2项表示真实关系下的项目向量与重构关系下的项目误差, 第3项是融合各种特征后防止模型过度拟合的 L_2 正则化。

4 实验及分析

设计实验去验证提出模型的推荐性能, 在内存32 GB, 处理器型号为AMD EPYC™ ROME的Windows Server 2012服务器中, 利用Tensorflow作为深度学习的框架, 使用Python3.5设计对比实验进行性能分析。

4.1 数据集

本文数据来源于公开数据集MovieLens(<https://grouplens.org/datasets/movielens>), 数据集中包含610个用户对9742部电影的100000多条1~5分范围内的评分数据。知识图谱数据源于MovieLens中统一资源定位符(Uniform Resource Locator, URL)在互联网电影资源库(Internet Movie DataBase, IMDB) (<https://www.imdb.com>)中的映射, 获取导演、作者、演员等辅助信息去构建知识图谱, 数据基本信息见表1。本实验将数据集按4:1的比例划分训练集和测试集进行对比实验分析。

4.2 实验评价指标

(1) 点击率预测。实验通过预测用户对电影的点击率对推荐性能分析。采用度量标准特征曲线下面积(Area Under Curve, AUC)^[9]和正确率(Accuracy, Acc)^[9]作为反映算法准确度的指标。

(2) Top-N列表推荐。实验通过给用户推荐N个项目的列表对推荐性能分析。采用度量标准为召回率(Recall@K)^[16]和准确率(Precision@K)^[16]作为衡量推荐列表的指标。

4.3 参数设置与对比分析

在本节讨论分析实验的具体参数设置, 其中 d 表示特征维度, h 表示链路长度, m 表示扩散偏好集的每层大小, λ_1 表示KGE损失权重, λ_2 表示 L_2 正则项权重。

为了测量特征维度 d 对推荐效果的影响, 分别设置 $d=4, 8, 16, 32, 64$ 对数据集进行实验, 实验结果如图3(a)所示。当维度 $d=8$ 时推荐效果达到最佳。最初, AUC随着 d 的增加而增加, 特征带来更多信息; 而当 d 一直增加时, 会带来过拟合现象, 导致模型性能下降。

为了测量链路长度 h 对推荐效果的影响, 分别设置 $h=2, 3, 4, 5$ 对数据集进行实验, 实验结果如图3(b)所示。结果显示当链路长度 $h=2$ 时推荐效果达到最佳。随着 h 的增加, 实体之间的关联减弱, 带来更多的噪声数据。过长的关系连接从知识图谱中挖掘出过多的无用信息, 过短的路径无法探索远端实体与用户之间的相关性和依赖性。

为了测量扩散偏好集每一层大小对推荐效果的影响, 分别设置 $m=8, 16, 32, 64$ 对数据集进行实验, 实验结果如图3(c)所示。结果显示当扩散偏好集 $m=32$ 时推荐效果达到最佳。一开始AUC随着 m 的增加而增加, 当 m 太大时带来更多的实体数据但实体间关联性减弱, 同时计算开销增加, 实际推荐效果下降。

为了确定损失函数中权重 λ_1, λ_2 , 分别在数据集上设置实验去选取合适的权重值。实验结果如图4所示。结果显示当 $\lambda_1=0.5, \lambda_2=10^{-7}$ 时推荐效果达到最佳。

综上所述, 实验的具体参数设置为特征维度 $d=8$, 扩散偏好集的层数 $h=2$, 扩散偏好集的每层大小 $m=32$, KGE损失权重 $\lambda_1=0.5$, L_2 正则项权重 $\lambda_2=10^{-7}$ 。

4.4 模型训练变化分析

在本节讨论分析实验模型随着训练次数的增加, 评价指标AUC和Acc在训练集和测试集的变化情况。实验结果如图5所示。

由图5可以看出, 随着训练次数的增加, 模型训练集和测试集上的AUC和Acc指标在训练20次左右达到最高值并开始收敛。在模型收敛后, 不断增加训练会致使模型在测试集上的AUC和Acc微弱下降, 但整体影响较小。

4.5 实验结果及分析

本文主要从模型预测准确性方面和Top-N列表

表1 实验数据

数据集	指标类型	指标值	数据集	指标类型	指标值
电影评分数据	用户数量	610	知识图谱数据	用户实体数量	610
	项目数量	9742		项目实体数量	9742
	评分数量	100836		演职人员关系	52904
	评分级别	0.5, 1, ..., 5		电影类别关系	24226
	电影海报数量	9730		项目图片数量	9730




图3 模型参数对AUC的影响




图4 模型权重对AUC的影响




图5 AUC和Acc评价指标随训练轮数的变化图

推荐方面分析融合知识图谱与图片信息的推荐模型 (integrating Knowledge Graph and Image features, KG-I)在MovieLens集上的性能表现。所有对比方法均采用4.2节指标进行性能衡量。在这一节,主要在数据集上进行以下实验:(1)比较本文所提模型和现有模型的效果;(2)研究多种特征对于推荐效果的影响,包括知识图谱的语义特征、结构特征以及图片特征;(3)研究模型在不同稀疏度数据子集的表现。

4.5.1 与其他对比模型比较

为了验证文中提出的模型性能,本文选取下面几种推荐相关模型作为对比。

基于贝叶斯个性化排序的矩阵分解(Matrix Factorization base Bayesian Personalized Ranking, BPRMF)^[24]:通过构建用户对不同物品的偏序关系进行协调过滤的推荐。

深度知识感知网络(Deep Knowledge-aware Network, DKN)^[12]:将知识图谱实体嵌入与卷积神经网络相融合,利用关系建模转换嵌入方法(Transe)对知识图谱进行项目表示,给用户进行推荐。

RippleNet^[9]:将知识图谱特征学习融入推荐系统,利用偏好扩散结合注意力机制得到用户的偏好特征进行推荐。

KG-I:利用深度游走和偏好扩散原理将知识

图谱的语义和结构特征相融合,同时融入项目图片特征进行推荐。

融合知识图谱语义特征和结构特征的推荐模型(integrating Knowledge Graph- Semantic and Structural features, KG-SS):该模型在KG-I的基础上融合知识图谱语义特征和结构特征,没有考虑项目图片特征。

基于知识图谱语义特征的推荐模型(integrating Knowledge Graph-Semantic features, KG-S):该模型仅仅考虑知识图谱的语义信息,没有考虑知识图谱的结构特征与项目图片特征。

实验设置点击率预测,比较各模型在数据集上的AUC和Acc,结果如表2所示,同时在Top-N列表推荐的场景下设置top-K=1, 5, 10, 20, 50, 100,比较各模型在数据集上的召回率和精确度,结果如图6所示。

观察表2和图6可以发现:

(1)在实验中,BPRMF的总体效果略微逊色于其他对比算法,这主要因为利用知识图谱的算法模型效果更好,知识图谱带来了更多项目潜在信息,从而提升了推荐效果。

(2)与RippleNet模型相比,RippleNet只是挖掘了知识图谱中的语义信息忽略了图谱本身自带的空间结构特征,因此效果略微逊色与KG-SS模型。

(3)KG-I算法的推荐性能比DKN,RippleNet算法在知识图谱的基础上加入了图片特征,这说明图片特征的融合有利于提高推荐算法的性能。

(4)BPRMF在准确率值上表现略高,召回率和准确率的指标是相互矛盾的,召回率越高准确率

越低。实际情况下需要保证召回率和准确率相对平衡。结合表中数据,BPRMF的推荐效果表现一般。

(5)本文方法在数据集上取得了最好的效果,因为它不仅挖掘知识图谱的语义特征和结构特征,同时融合项目的图片特征,丰富了用户的历史偏好数据集。

实验结果表明:KG-I模型更好地利用知识图谱的特征,融合多种数据信息提高推荐效果。

4.5.2 多种特征对于推荐效果的影响

为了研究本文所提融合知识图谱语义特征、结构特征、图片特征对于推荐效果的影响,设置实验进行对比。

KG-S:该模型仅仅考虑知识图谱的语义信息,没有考虑知识图谱的结构特征与项目图片特征。

KG-SS:该模型融合知识图谱语义特征和结构特征,没有考虑项目图片特征。

KG-I:该模型融合知识图谱语义特征、结构特征和项目图片特征。

融合知识图谱语义特征与图片特征的推荐模型(integrating Knowledge Graph- Semantic and Image feature, KG-SI):该模型不仅仅考虑知识图谱的语义信息,同时引入项目图片特征,没有挖掘知识图谱结构特征。

该实验设置top-K=1, 5, 10, 20, 50, 100比较各模型在数据集上的召回率和精确度,结果如图7所示。

从图7可以看出:

(1)KG-I模型比KG-SS模型推荐效果好,说明在原有知识图谱的基础上图片特征的引入提高了模型的推荐效果;

表2 在MovieLens集上各种算法AUC和Acc对比

	BPRMF	DKN	RippleNet	KG-I	KG-SS	KG-S
AUC	0.7137	0.7925	0.8353	0.8544	0.8438	0.8345
Acc	0.6396	0.7268	0.7769	0.7880	0.7756	0.7802




图6 不同模型的召回率和准确率

(2) KG-I模型与KG-SI相比，召回率有明显提升的同时准确率也有所提升，这说明知识图谱的结构特征对推荐效果有着重要影响，不能完全忽略。

(3) KG-I模型的推荐效果是最好的，说明同时考虑了知识图谱的结构特征、语义特征与项目图片特征时，模型效果最好。

实验结果表明，知识图谱的结构特征、语义特征和项目图片特征的融合能够有效地提高推荐的效果。KG-I模型的特征融合优于现有的利用知识图谱的推荐效果。

4.5.3 稀疏性验证

为了验证模型在不同稀疏度数据集的表现，该实验分别对训练集抽取了不同的数据集设置实验进行对比。

步骤1 在原有训练集的基础上，随机选取20%的数据，降低数据密度，分别在不同模型上进行实验。

步骤2 在原有训练集的基础上，随机选取50%的数据，降低数据密度，分别在不同模型上进行实验。

步骤3 在原有训练集的基础上，随机选取80%的数据，降低数据密度，分别在不同模型上进行实验。

该实验设置top-K=1, 5, 10, 20, 50, 100，比较各模型在数据集上的召回率，结果如图8所示。

从图8可以看出：

(1) 与KG-I模型类似，RippletNet模型随着数据越来越稀疏，利用知识图谱的模型的召回率变化大，推荐效果的优势越来越明显。这说明考虑知识图谱的推荐，较好地缓解了数据稀疏性的问题。

(2) 无论数据的稀疏度如何，KG-I的召回率指标变化不大基本不受数据稀疏度的影响。而BPRMF模型有明显的降低，说明BPRMF模型受数据稀疏度影响较大。

(3) 在越稀疏的数据集上，KG-I模型的推荐效果越明显。随着数据密度的上升，其他算法的推荐效果有明显的回升。

实验结果表明：相比于其他的推荐模型，KG-I模型在数据较为稀疏的情况下依旧能够有很好的推荐效果，KG-I模型有效地缓解数据稀疏问题。

5 结束语

本文完成知识图谱与推荐领域的结合，提出一种融合知识图谱与图片特征的推荐模型(KG-I)。文中将知识图谱结构嵌入、知识嵌入和视觉嵌入作为不同模态输入，并保持各模态间的对应关系，以用户对项目的隐式反馈作为衔接，对3种不同的嵌入表示更好的融合，以此提高推荐算法的性能。需要注意的是知识图谱的实体和现实用户项目等具体的




图7 不同特征的召回率和准确率




图8 不同数据稀疏度的召回率

映射。结果表明,知识图谱的结构特征、知识特征以及视觉特征对推荐效果有着重要影响不能忽略,同时融合知识图谱与图片特征的个性化推荐模型完全优于其他的对比算法并且缓解数据稀疏情况。

本文在各个模态之间相对较为独立,一定程度上的丢失不同模态之间的依赖和对应关系。多模态融合方法采取较为基础的后端融合,使得不同模态下的错误互不影响不会造成错误累积,因此使得多模态数据之间互补性较差,但能够直观地对比出不同模态对推荐效果的影响,有一定的参考价值。

参 考 文 献

- [1] TEWARI A S. Generating items recommendations by fusing content and user-item based collaborative filtering[J]. *Procedia Computer Science*, 2020, 167: 1934–1940. doi: [10.1016/J.PROCS.2020.03.215](https://doi.org/10.1016/J.PROCS.2020.03.215).
- [2] ZENG Lanying and XIE Xiaolan. Collaborative filtering recommendation based on CS-kmeans optimization clustering[C]. The 4th International Conference on Intelligent Information Processing, New York, USA, 2019: 334–340. doi: [10.1145/3378065.3378129](https://doi.org/10.1145/3378065.3378129).
- [3] HUANG Liusheng, CHEN Huaping, WANG Xun, *et al.* A fast algorithm for mining association rules[J]. *Journal of Computer Science and Technology*, 2000, 15(6): 619–624. doi: [10.1007/BF02948845](https://doi.org/10.1007/BF02948845).
- [4] 戴琳, 孟祥武, 张玉洁, 等. 融合多种数据信息的餐馆推荐模型[J]. *软件学报*, 2019, 30(9): 2869–2885. doi: [10.13328/j.cnki.jos.005540](https://doi.org/10.13328/j.cnki.jos.005540).
DAI Lin, MENG Xiangwu, ZHANG Yujie, *et al.* Restaurant recommendation model with multiple information fusion[J]. *Journal of Software*, 2019, 30(9): 2869–2885. doi: [10.13328/j.cnki.jos.005540](https://doi.org/10.13328/j.cnki.jos.005540).
- [5] CHENG H T, KOC L, HARMSSEN J, *et al.* Wide & deep learning for recommender systems[C]. The 1st Workshop on Deep Learning for Recommender Systems, New York, USA, 2016: 7–10. doi: [10.1145/2988450.2988454](https://doi.org/10.1145/2988450.2988454).
- [6] HE Xiangnan, LIAO Lizi, ZHANG Hanwang, *et al.* Neural collaborative filtering[C]. The 26th International Conference on World Wide Web, Republic and Canton of Geneva, Switzerland, 2017: 173–182. doi: [10.1145/3038912.3052569](https://doi.org/10.1145/3038912.3052569).
- [7] ZHOU Guorui, ZHU Xiaoqiang, SONG Chengru, *et al.* Deep interest network for click-through rate prediction[C]. The 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, London, UK, 2018: 1059–1068.
- [8] TAN Y K, XU Xinxing, and LIU Yong. Improved recurrent neural networks for session-based recommendations[C]. The 1st Workshop on Deep Learning for Recommender Systems, New York, USA, 2016: 17–22. doi: [10.1145/2988450](https://doi.org/10.1145/2988450).
- [9] WANG Hongwei, ZHANG Fuzheng, WANG Jialin, *et al.* RippleNet: Propagating user preferences on the knowledge graph for recommender systems[C]. The 27th ACM International Conference on Information and Knowledge Management, New York, USA, 2018: 417–426. doi: [10.1145/3269206.3271739](https://doi.org/10.1145/3269206.3271739).
- [10] WANG Hongwei, ZHANG Fuzheng, ZHAO Miao, *et al.* Multi-task feature learning for knowledge graph enhanced recommendation[C]. The World Wide Web Conference, New York, USA, 2019: 2000–2010. doi: [10.1145/3308558.3313411](https://doi.org/10.1145/3308558.3313411).
- [11] ABU-EL-HAIJA S, PEROZZI B, KAPOOR A, *et al.* MixHop: Higher-order graph convolutional architectures via sparsified neighborhood mixing[C]. The 36th International Conference on Machine Learning, Long Beach, USA, 2019: 21–29.
- [12] WANG Hongwei, ZHANG Fuzheng, XIE Xing, *et al.* DKN: Deep knowledge-aware network for news recommendation[C]. The 2018 World Wide Web Conference, Lyon, France, 2018: 1835–1844. doi: [10.1145/3178876.3186175](https://doi.org/10.1145/3178876.3186175).
- [13] ZHAO Huan, YAO Quanming, LI Jianda, *et al.* Meta-graph based recommendation fusion over heterogeneous information networks[C]. The 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New York, USA, 2017: 635–644. doi: [10.1145/3097983.3098063](https://doi.org/10.1145/3097983.3098063).
- [14] DAI Feifei, GU Xiaoyan, LI Bo, *et al.* Meta-graph based attention-aware recommendation over heterogeneous information networks[C]. 19th International Conference on Computational Science, Faro, Portugal, 2019: 580–594.
- [15] PEROZZI B, AL-RFOU R, and SKIENA S. DeepWalk: Online learning of social representations[C]. The 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New York, USA, 2014: 701–710. doi: [10.1145/2623330.2623732](https://doi.org/10.1145/2623330.2623732).
- [16] 程淑玉, 黄淑桦, 印鉴. 融合知识图谱与循环神经网络的推荐模型[J]. *小型微型计算机*, 2020, 41(8): 1670–1675.
CHENG Shuyun, HUANG Shuhua, and YIN Jian. Recommendation model based on knowledge graph and recurrent neural network[J]. *Journal of Chinese Computer Systems*, 2020, 41(8): 1670–1675.
- [17] WANG Xiang, XU Yaokun, HE Xiangnan, *et al.* Reinforced negative sampling over knowledge graph for recommendation[C]. The Web Conference, New York, USA, 2020: 99–109. doi: [10.1145/3366423.3380098](https://doi.org/10.1145/3366423.3380098).
- [18] ZHANG Fuzheng, YUAN N J, LIAN Defu, *et al.* Collaborative knowledge base embedding for recommender systems[C]. The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New

- York, USA, 2016: 353–362. doi: [10.1145/2939672.2939673](https://doi.org/10.1145/2939672.2939673).
- [19] YU Xiao, REN Xiang, SUN Yizhou, *et al.* Personalized entity recommendation: A heterogeneous information network approach[C]. The 7th ACM International Conference on Web Search and Data Mining, New York, USA, 2014: 283–292. doi: [10.1145/2556195.2556259](https://doi.org/10.1145/2556195.2556259).
- [20] MOUSSELY-SERGIEH H, BOTSCHEH T, GUREVYCH I, *et al.* A multimodal translation-based approach for knowledge graph representation learning[C]. The 7th Joint Conference on Lexical and Computational New Orleans, USA, 2018: 225–234. doi: [10.18653/v1/S18-2027](https://doi.org/10.18653/v1/S18-2027).
- [21] PEZESHKPOUR P, CHEN Liyan, and SINGH S. Embedding multimodal relational data for knowledge base completion[C]. The Conference on Empirical Methods in Natural Language Processing, Brussels, Belgium, 2018: 3208–3218. doi: [10.18653/v1/D18-1359](https://doi.org/10.18653/v1/D18-1359).
- [22] YUAN M and LIN Y. Model selection and estimation in regression with grouped variables[J]. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2006, 68(1): 49–67. doi: [10.1111/J.1467-9868.2005.00532.X](https://doi.org/10.1111/J.1467-9868.2005.00532.X).
- [23] JONATHON S. A tutorial on principal component analysis[J]. *International Journal of Remote Sensing*, 2014, 51(2): 2–12. doi: [10.13140/2.1.1593.1684](https://doi.org/10.13140/2.1.1593.1684).
- [24] RENDLE S, FREUDENTHALER C, GANTNER Z, *et al.* BPR: Bayesian personalized ranking from implicit feedback[C]. The 25th Conference on Uncertainty in Artificial Intelligence, Arlington, USA, 2009: 452–461.
- 陈乔松：男，1978年生，副教授，研究方向为图像检索系统等。
郭傲东：男，1997年生，硕士生，研究方向为个性化推荐算法研究。
杜雨露：男，1987年生，讲师，研究方向为个性化推荐算法研究等。
张怡文：女，1980年生，教授，研究方向为个性化推荐算法研究。
朱 越：女，1997年生，硕士生，研究方向为知识工程。
- 责任编辑：余 蓉