

基于知识图谱与图注意力网络的推荐算法

范紫萱¹ 刘 继¹
FAN Zixuan LIU Ji

摘要

推荐系统作为解决信息过载问题的关键手段，在为用户提供个性化内容和服务方面发挥着重要作用，同时也面临着数据稀疏性和冷启动等挑战。为了应对这些挑战，将知识图谱作为辅助信息与基于图神经网络的推荐算法相结合，提出了一种创新的推荐算法——KGAE (knowledge graph attention recommendation of transe)。首先利用用户项目交互图和项目知识图谱构建协同知识图 CKG (collaborative knowledge graph)，然后将翻译距离模型 TransE 嵌入到图注意力网络中，使用 GraphSAGE 技术来更新目标节点的表示，通过注意力机制来区分邻居的重要性，提高推荐的准确性。在两个公共数据集上与五个主流推荐算法进行对比实验，结果表明所提方法能够显著提升推荐效果。

关键词

推荐系统；知识图谱；图注意力网络；TransE 模型；注意力机制

doi: 10.3969/j.issn.1672-9528.2024.12.016

0 引言

随着信息技术的飞速发展，互联网作为信息传播的主要载体，其信息量呈现出“爆炸式”增长态势。根据中国互联网络信息中心 (CNNIC) 最新发布的权威统计数据，截至 2023 年 12 月，全国的网民数量已达到 10.92 亿，互联网普及率为 77.5%^[1]。在此背景下，信息过载问题日益凸显，面对互联网上海量的信息资源，用户如何快速找到符合自我需求的内容成为一个亟待解决的问题。因此，推荐系统将机器学习和数据挖掘技术相结合，成为为用户提供个性化推荐，帮助用户发现感兴趣内容的重要工具。

基于推荐系统在面对新用户或新项目时，因没有历史数据可供分析出现的冷启动问题，本文提出了一种改进的 KGAT 推荐算法 KGAE (knowledge graph attention recommendation of transe)，该方法基于 KGAT 模型，通过引入翻译距离模型 TransE 优化节点的嵌入，有效缓解了过拟合问题。同时使用 GraphSAGE 技术递归地采样和聚合邻居节点的信息来更新目标节点的表示，并使用注意力机制来区分节点的重要性，提高了推荐的准确性。最后为验证该推荐算法的有效性，在两个公开数据集 Movielens-1M 与 Last.FM 进行实验，证明了该算法在提升推荐准确性上具有显著效果。

1. 新疆财经大学统计与数据科学学院 新疆乌鲁木齐 830012
[基金项目] 国家自然科学基金资助项目“大数据背景下网络舆情智能治理：共同体构建、协同演进与引导机制”(72164034)；新疆社会科学基金项目“新疆游客网络评论情感特征图谱分析与智慧旅游优化策略研究”(2024BTJ057)

1 相关工作

基于内容的推荐是最早的推荐算法，它是根据用户之前的行为和偏好，以及项目本身的特征和属性信息，如文本描述、标签、关键词等，通过余弦相似度、皮尔逊相关系数等方法计算相似度，向用户推荐与其兴趣相关的内容。但此推荐算法主要依赖用户自身的行为数据，而不涉及其他用户的行为数据，无法充分利用用户之间的信息交互来提高推荐效果，无法挖掘用户潜在的兴趣。

自深度学习技术诞生以来，因其强大的特征表达能力和灵活的模型结构，被应用到推荐算法领域。刘园园^[2]提出了一种融合读者兴趣的深度学习推荐算法，采用长短期记忆网络 (long-short term memory, LSTM) 模型，对历史借阅信息进行提取，挖掘读者动态兴趣偏好，提高推荐精度。王瑞平等人^[3]将多头注意力机制引入到 DeepFM 模型中，针对多样化的推荐对象，动态地捕获并学习用户的个性化表征，提供了更加精准与个性化的推荐。

图神经网络在针对非欧几里得空间数据的特征表征及复杂图结构数据的处理能力上展现出显著优势，为推荐系统领域的演进开辟了新颖的路径。将用户与物品视作图结构中的节点，而用户与物品之间的交互行为则形成图中的边，利用图神经网络学习用户和物品的表示，每个节点都可以获取到高阶邻居信息，再将它们映射到低维空间中，能够更好地建模用户、物品以及它们之间复杂的关系，从而提升推荐的准确性和个性化程度^[4]。Ying 等人^[5]提出了一个基于图卷积神经网络 (graph convolution neural networks, GCN) 的推荐模型，该模型首先构建了一个用户-物品交互图，然后使用 GCN 来

学习用户和物品的嵌入表示。基于 GCN 的推荐也是最基本的图神经网络推荐形式。杨宝生^[6]提出了一种基于图神经网络和注意力机制的新闻推荐模型,应用 GCN 对用户和新闻的表示进行学习,并引入注意力机制,根据用户的历史行为,动态地调整不同新闻对用户兴趣的贡献度。

引入知识图谱至推荐算法领域,能够有效缓解传统推荐算法所遭遇的数据稀疏性与冷启动难题。基于知识图谱的推荐算法主要可以分为三类:嵌入方法、路径方法以及结合路径和嵌入的混合方法。嵌入方法的核心在于通过嵌入技术,将图谱中的实体与关系转换为低维向量形式,最具代表性的嵌入方法包括基于翻译距离模型的 TransE、TransH 和 TransR 等。Zhang 等人^[7]提出了 CFKG 模型,该模型首先构建了一个涵盖用户和项目信息知识图谱,利用 TransE 对图进行编码,最后根据欧氏距离来对物品进行排序。曹玖新等人^[8]在研究中提出了一种创新的基于元路径的兴趣点推荐算法。引入了元路径的概念,以精确描述节点间多样化的关联关系。运用随机游走技术计算元路径的特征值,通过监督学习方法确定各特征的权重,依据用户在各兴趣点的签到概率,生成精准的推荐列表。Wang 等人^[9]提出了水波网络(RippleNet),引入偏好传播的概念,利用物品的知识图谱一层一层地往外扩散后提取节点,每一层的物品会影响到在它之后的所有层,但越往外对结果的影响就越小。该模型能够根据用户的历史记录自动发现其潜在兴趣,并生成个性化的推荐结果。近年来,研究者们又将基于嵌入和路径方法结合起来,以充分利用知识图谱中的结构和语义信息。Wang 等人^[10]创新性地提出了知识图谱卷积网络(knowledge graph convolutional networks, KGCN),通过对知识图谱的实体和关系进行多层传播和聚合,形成更丰富的特征表示,捕捉实体间的隐藏关联,更好地预测了用户对项目的交互概率。熊中敏等人^[11]提出了融合用户偏好的图神经网络推荐模型,通过用户在知识图谱中的历史交互记录,动态地传播并强化用户的个性化偏好表征,同时从广度与深度两个维度出发,全面捕获到高阶网络连通性特征与混合分层的信息结构,丰富并优化项目的表示向量。Wang 等人^[12]又提出了知识图谱注意力网络(knowledge graph attention network, KGAT)将用户-项目二部图和项目知识图谱相结合,构建 CKG(collaborative knowledge graph)实现了更高阶的关系建模,同时采用图注意力网络进行消息传递,聚合出物品向量之后与用户向量进行计算得到预测值。唐宏等人^[13]深度融合了知识图谱的丰富语义信息与神经网络的强大学习能力,并引入注意力机制,动态捕捉用户的兴趣变化。郭伟等人^[14]提出一种基于协同信号的知识图谱注

意力网络推荐算法,将用户的历史项目和待推荐项目在知识图谱中进行传播,并采用集合边信息的图注意力网络来学习用户和项目特征。

图神经网络的出现深刻影响着推荐算法的发展,为其提供了解决问题的新方法。图注意力网络解决了传统图神经网络在聚合邻居节点信息时无法区分不同邻居节点重要性的问题,通过动态调整节点间的权重来优化信息的聚合过程,且只需知道每个节点的邻节点信息。知识图谱也属于一种图,在图神经网络兴起后,产生了二者结合的推荐算法,特别是 KGAT 能够显式地利用知识图谱中的高阶连接信息,有助于更全面地理解用户和项目之间的关系,从而提升推荐的准确性。引入知识图谱的图注意力网络还能深入挖掘更复杂的、多阶的关系路径,从而提供更全面、准确的推荐。

2 KGAE 模型

首先,需要构建协同知识图谱(collaborative knowledge graph, CKG),它是由用户-项目交互图 G_1 和项目知识图谱 G_2 构成。

用户集 $U = \{u_1, u_2, \dots, u_N\}$ 和项目集 $I = \{i_1, i_2, \dots, i_M\}$ 是两组实体, y_{ui} 反映了用户项目的交互关系,当 $y_{ui}=1$ 表示用户 u 与项目 i 有交互行为,反之 $y_{ui}=0$ 。 G_1 定义为:

$$G_1 = \{(u, y_{ui}, i)\} \begin{cases} u \in U \\ i \in I \\ y_{ui} \begin{cases} 1 & u \text{ 和 } i \text{ 有交互} \\ 0 & u \text{ 和 } i \text{ 无交互} \end{cases} \end{cases} \quad (1)$$

项目知识图谱 $G_2 = \{(h, r, t) | h \in E, r \in R, t \in E\}$, 其中 h 、 r 和 t 分别表示三元组的头实体、关系和尾实体,而 E 和 R 表示实体和关系的集合,其中每个三元组描述了从头实体 h 到尾实体 t 的关系 r 。例如三元组(霸王别姬,类型,爱情片)表示《霸王别姬》这部电影属于爱情片。

本文构建了一个 KGAE 的模型,其整体架构如图 1 所示,该模型主要由三大部分构成。




图 1 模型框架

第一部分为知识图谱嵌入层，该层将 CKG 的结构特性予以保留，并将图中的每个节点转化为向量形式进行参数化表示；第二部分为注意嵌入传播层，此层通过递归方式传播节点邻居的嵌入信息，以实现节点表示的更新，同时，在传播过程中，采用了一种知识感知的注意力机制，用以学习并分配每个邻居节点的权重；第三部分为预测层，该层负责整合来自所有传播层的用户与项目表示信息，并基于这些信息生成预测的评分。

2.1 知识图谱嵌入层

知识图谱嵌入层是将知识图谱的实体和关系参数化为向量表示传入模型，在图 1 中以 u_1 和 i_1 两个节点为例。本文将采用翻译距离模型 TransE 进行知识图谱的嵌入。翻译距离模型是将尾向量视作由头向量经过关系向量的翻译距离所得到的。TransE 的距离计算公式为：

$$d(\mathbf{h} + \mathbf{r}, \mathbf{t}) = \|\mathbf{h} + \mathbf{r} - \mathbf{t}\|_2 \quad (2)$$

式中： $\mathbf{h}$ 是头实体的嵌入向量； $\mathbf{r}$ 是关系的嵌入向量； $\mathbf{t}$ 是尾实体的嵌入向量； $\|\cdot\|_2$ 是 L_2 范数的计算符号，用于计算向量的模长。TransE 模型将实体与关系映射至统一的向量空间中，把 $\mathbf{r}$ 视为连接 $\mathbf{h}$ 和 $\mathbf{t}$ 的平移向量，即 $\mathbf{h} + \mathbf{r} \approx \mathbf{t}$ 。TransE 模型图如图 2 所示。




图 2 TransE 模型图

2.2 注意嵌入传播层

注意嵌入传播层主要通过图注意力网络进行消息传递，聚合实体及关系的信息，并通过注意力权重区分不同连接的重要程度。

实体的注意力权重是由头实体 $\mathbf{h}$ 、尾实体 $\mathbf{t}$ 和关系 $\mathbf{r}$ 的三个向量计算而来的，其公式为：

$$a(\mathbf{h}, \mathbf{r}, \mathbf{t}) = \text{Softmax}(\mathbf{W}_r \mathbf{e}_t)^T \cdot \tanh(\mathbf{W}_r \mathbf{e}_h + \mathbf{e}_r) \quad (3)$$

式中： $\mathbf{e}_h$ 和 $\mathbf{e}_t$ 是维度为 e_dim 的头尾实体向量； $\mathbf{e}_r$ 是维度为 r_dim 的关系向量； $\mathbf{W}_r$ 是关系变换矩阵，维度为 $e_dim \times r_dim$ 。tanh 为非线性激活函数，注意力得分取决于在空间中目标实体和邻居实体的距离，即 $\mathbf{e}_h + \mathbf{e}_r$ 。最后使用 Softmax 函数来归一化计算邻居实体的权重。然后在头实体的位置初步

聚合，其公式为：

$$\mathbf{e}_{N_h} = \sum_{(\mathbf{h}, \mathbf{r}, \mathbf{t}) \in N_h} a(\mathbf{h}, \mathbf{r}, \mathbf{t}) \times \mathbf{e}_t \quad (4)$$

式中： $(\mathbf{h}, \mathbf{r}, \mathbf{t}) \in N_h$ 是指遍历头实体的邻居尾实体和连接它们的关系，而该头实体在计算过程中将被广播。

消息传递示意图如图 3 所示。得到初步的聚合向量 $\mathbf{e}_{N_h}$ 后，需要将其与原始头实体向量 $\mathbf{e}_h$ 进行消息聚合。本文采用 GraphSAGE 进行拼接聚合，它包含采样和聚合两个步骤。




图 3 消息传递示意图

在图结构中，一个节点的邻居数量可能非常多，如果要考虑所有的邻居节点将导致计算复杂度过高，因此，GraphSAGE 通过采样技术来限制参与每个节点表示学习的邻居数量。它会从其邻居中随机选择一部分节点作为该节点的“采样邻居”，然后再拼接聚合原始头实体向量 $\mathbf{e}_h$ 和聚合向量 $\mathbf{e}_{N_h}$ 以更新节点的表示，计算公式为：

$$\text{agg}_{\text{concat}} = \text{LeakyReLU}(\mathbf{W}(\mathbf{e}_h \parallel \mathbf{e}_{N_h})) \quad (5)$$

式中：LeakyReLU 是非线性激活函数； $\parallel$ 表示进行拼接操作。

上述是单层的注意嵌入传播的计算方法，在现实模型中可以扩展到多层以获得更高阶的结构信息，从而更深入地探索用户的潜在兴趣。对于一个 l 层的模型，可以递归地进行实体表示，以此捕捉和整合各层级的邻居信息，计算公式为：

$$\mathbf{e}^{(l)} = f(\mathbf{e}_h^{(l-1)}, \mathbf{e}_{N_h}^{(l-1)}) \quad (6)$$

在 l 层网络中，实体 h 的信息为：

$$\mathbf{e}_{N_h}^{(l-1)} = \sum_{(\mathbf{h}, \mathbf{r}, \mathbf{t}) \in N_h} a(\mathbf{h}, \mathbf{r}, \mathbf{t}) \mathbf{e}_t^{(l-1)} \quad (7)$$

式中： $\mathbf{e}_t^{(l-1)}$ 表示在第 $(l-1)$ 层邻居收集信息后生成实体 t 的表示。

2.3 预测层

模型经过 l 层后，得到用户节点 u 的多个表示 $\{\mathbf{e}_u^{(1)}, \dots, \mathbf{e}_u^{(l)}\}$ ，项目节点 i 的多个表示 $\{\mathbf{e}_i^{(1)}, \dots, \mathbf{e}_i^{(l)}\}$ 。将每一层的表示连接起来，计算公式为：

$$\mathbf{e}_u^* = \mathbf{e}_u^{(0)} \parallel \dots \parallel \mathbf{e}_u^{(l)}, \mathbf{e}_i^* = \mathbf{e}_i^{(0)} \parallel \dots \parallel \mathbf{e}_i^{(l)} \quad (8)$$

最后，通过对用户表示向量和项目表示向量进行内积计算，获得它们之间的匹配分数，计算公式为：

$$\hat{y}(u, i) = \mathbf{e}_u^{*T} \mathbf{e}_i^* \quad (9)$$

2.4 模型优化

获得最终预测匹配分数之后，为优化推荐模型，本文选择BPR损失函数。假定在用户与项目之间的实际交互行为（即已观察到的）应获得相较于未被观测到的潜在交互更高的预测权重，计算过程为：

$$\mathcal{L}_{CF} = \sum_{(u,i,j) \in \mathcal{O}} -\ln \sigma(\hat{y}(u, i) - \hat{y}(u, j)) \quad (10)$$

式中： $\mathcal{O} = \{(u, i, j) | (u, i) \in \mathcal{R}^+, (u, j) \in \mathcal{R}^-\}$ 表示训练集，如果用户 u 与项目 i 之间有交互行为为 $\mathcal{R}^+$ ，未有交互行则为 $\mathcal{R}^-$ ， $\sigma(\cdot)$ 是sigmoid激活函数^[15]。

在进行知识图谱嵌入的损失公式为：

$$\mathcal{L}_{KG} = \sum_{(h,r,t,t')} -\ln \sigma(a(\mathbf{h}, \mathbf{r}, \mathbf{t}') - a(\mathbf{h}, \mathbf{r}, \mathbf{t})) \quad (11)$$

最后将两个函数联合起来，计算公式为：

$$\mathcal{L}_{KGAE} = \mathcal{L}_{KG} + \mathcal{L}_{CF} + \lambda \|\theta\|_2^2 \quad (12)$$

式中： $\theta = \{E, \mathbf{W}_r, \forall l \in \mathcal{R}, \mathbf{W}_1^{(l)}, \mathbf{W}\mathbf{W}_2^{(l)}, \forall l \in \{1, \dots, L\}\}$ ， E 是一个嵌入表，集成了所有实体与关系的向量化表示，针对过拟合现象，采用 L_2 正则化技术防止过拟合， λ 为正则化系数。

3 实验分析

3.1 数据集及实验设置

本文使用两个公开数据集 MovieLens-1M 和 Last.FM 进行实验比较，以评估 KGAE 模型的性能。

MovieLens-1M：电影推荐中广泛使用的基准数据集，它是由 MovieLens 用户提供的电影评分（评分为 1~5）数据。

Last.FM：从 Last.FM 在线音乐平台中收集的用户音乐评分数据。

两个数据集的统计数据如表 1 所示。

表 1 数据集统计信息

Classification		MovieLens-1M	Last.FM
User-Item Interaction	User	6036	23 566
	Item	2442	48 123
	Interaction	753 556	3 034 796
Knowledge Graph	Entities	182 011	58 266
	Relations	12	9
	Triplets	1 241 995	464 567

在本文的实验中，将数据集划分为：训练集、测试集与验证集，80% 的数据被用于模型训练，10% 作为测试集用来评估模型的性能，剩余的 10% 则为验证集，用于验证模型的有效性。实验环境配置如表 2 所示。

表 2 实验环境配置

实验环境	参数配置
编程语言	Python 3.9
操作系统	Windows 11
框架	PyTorch
CPU	Intel(R)Core(TM) i5-9300H
显卡	NVIDIA GeForce GTX 1660Ti

实验超参数设置如表 3 所示。

表 3 超参数配置

超参数	数值
实体与关系嵌入维度	64
批量大小	1024
邻居节点数量	10
训练轮次	20
学习率	0.01

3.2 评价指标

为评估模型的性能，引入混淆矩阵的概念，并将精确率（Precision）、召回率（Recall）、 F_1 值作为本实验的评价指标。精确率衡量模型预测为正例的准确性，即推荐给用户的项目中有多少是用户真正感兴趣的。召回率衡量模型发现所有正例的能力，即所有用户感兴趣的项目中有多少被成功推荐给用户了。 F_1 值作为精确率与召回率之间的调和平均值，综合考虑模型在正确预测正例与识别所有正例方面的能力，为模型评估提供了一个更为全面且均衡的评估视角。对应公式分别为：

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (13)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (14)$$

$$F_1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (15)$$

式中：TP 代表正确分类的数量；FP 代表错误分类的非数量；FN 代表错误分类的数量。

3.3 实验结果与分析

本文选择了 CKE、Ripplenet、GCN、GAT、KGCN 五个模型与 KGAE 模型进行对比分析，以验证其在提升推荐精度等方面的优势。六种推荐模型在 MovieLens-1M 和 Last.FM 数据集上的实验结果分别如表 4 和表 5 所示。

表 4 MovieLens-1M 数据集的实验结果

Model	Precision	Recall	F_1 -score
CKE	0.710	0.759	0.734
Ripplenet	0.741	0.799	0.769
GCN	0.805	0.847	0.825
GAT	0.886	0.885	0.885
KGCN	0.859	0.873	0.866
KGAE	0.897	0.912	0.904

表 5 Last.FM 数据集的实验结果

Model	Precision	Recall	F_1 -score
CKE	0.707	0.689	0.698
Ripplenet	0.747	0.733	0.740
GCN	0.738	0.813	0.774
GAT	0.871	0.878	0.873
KGCN	0.807	0.816	0.811
KGAE	0.887	0.896	0.891

通过在两个数据集上的输出结果可知,本文所提出的 KGAE 模型相较于 CKE、Ripplenet、GCN、GAT、KGCN 模型各项指标均有所提升。在 Movielens-1M 数据集中, Precision、Recall 和 F_1 值与对比模型中表现最好的模型相比分别提升了 1.1%、2.7% 和 1.9%。在 Last.FM 数据集中, Precision、Recall 和 F_1 值与对比模型中表现最好的模型相比分别提升了 1.6%、2.1% 和 1.8%。实验结果证明 KGAE 推荐模型具有更高的准确率,模型性能更加优越。

4 结论

本文首先利用用户-项目交互图和项目知识图谱构建 CKG。通过翻译距离模型 TransE 嵌入到图注意力网络中,使用 GraphSAGE 技术递归地采样和聚合邻居节点的信息来更新目标节点的表示,更新目标节点的表示,通过注意力机制来区分邻居的重要性。在 Movielens-1M 和 Last.FM 两个公共数据集上进行实验,验证了本文算法的有效性,说明通过获得知识图谱中的结构信息可以提高推荐的性能,有效缓解了冷启动问题。未来的研究工作将从两个方面进行:一是考虑社交网络关系对推荐结果的影响,二是如何利用用户的长期行为数据来构建模型,捕捉用户兴趣随时间的演变过程,以增进推荐的个性化和多样性。

参考文献:

[1] 第 53 次《中国互联网络发展状况统计报告》发布[J]. 新闻论坛, 2024,38(2):17.

[2] 刘园园. 基于读者兴趣挖掘的深度学习推荐模型[J]. 西南大学学报(自然科学版), 2023,45(4):201-209.

[3] 王瑞平, 贾真, 刘畅, 等. 基于 DeepFM 的深度兴趣因子分解机网络[J]. 计算机科学, 2021,48(1):226-232.

[4] GAO C, ZHENG Y, LI N, et al. A survey of graph neural networks for recommender systems: Challenges, methods and directions[J]. ACM transactions on recommender systems, 2023,1(1): 1-51.

[5] YING R, HE R N, CHEN K F, et al. Graph convolutional neural networks for web-scale recommender systems[C]//Pro-

ceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining. New York: ACM, 2018: 974-983.

[6] 杨宝生. 基于注意力机制增强图卷积神经网络的个性化新闻推荐[J]. 兰州文理学院学报(自然科学版), 2020, 34(5): 52-57.

[7] ZHANG Y F, AI Q Y, CHEN X, et al. Learning over knowledge-base embeddings for recommendation[J]. Special issue on collaborative filtering and recommender systems, 2018, 11(9): 137.

[8] 曹玖新, 董羿, 杨鹏伟, 等. LBSN 中基于元路径的兴趣点推荐[J]. 计算机学报, 2016,39(4):675-684.

[9] WANG H W, ZHANG F Z, WANG J L, 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 Italy. New York: ACM, 2018:417-426.

[10] WANG H W, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems[C]//Proceedings of the 28th International Conference on the World Wide Web Conference. New York: ACM, 2019: 3307-3313.

[11] 熊中敏, 舒贵文, 郭怀宇. 融合用户偏好的图神经网络推荐模型[J]. 计算机科学, 2022,49(6):165-171.

[12] WANG X, HE X N, CAO Y X, 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: ACM, 2019: 950-958.

[13] 唐宏, 范森, 唐帆, 等. 融合知识图谱与注意力机制的推荐算法[J]. 计算机工程与应用, 2022,58(5):94-103.

[14] 郭伟, 裴帅华. 基于协同信号的知识图注意力网络推荐算法[J]. 计算机工程与设计, 2024,45(3):911-917.

[15] 范洪玉, 张永库, 孟祥福. 基于知识图残差注意力网络的推荐方法[J]. 计算机科学, 2023,50(S2):479-485.

【作者简介】

范紫莹(2001—), 女, 四川宜宾人, 硕士, 研究方向: 大数据分析、推荐系统。

刘继(1974—), 男, 四川达州人, 博士, 教授, 研究方向: 数据智能分析、推荐系统。

(收稿日期: 2024-08-24)