

基于知识子图与注意力机制的在线课程推荐模型

王 烁¹, 顾亦然^{1,2}, 黄丽亚³

(1. 南京邮电大学 自动化、人工智能学院, 江苏 南京 210023;

2. 南京邮电大学 智慧校园研究中心, 江苏 南京 210023;

3. 南京邮电大学 电子与光学工程学院微电子学院, 江苏 南京 210023)

摘 要:推荐系统可以帮助用户在海量的资源中筛选出满足其需求的项目,不断发展的推荐系统为在线教育提供了新的思路。在线课程资源推荐作为在线教育领域中的重要一环,目前存在课程资源过载和课程推荐结果缺乏可解释性的问题。对此,该文提出了一种基于知识子图与注意力机制的在线课程推荐模型,以利用知识子图进行推荐。有别于直接利用知识图谱进行推荐而忽略了知识表示不准确问题的模型,该模型首先采用 Node2vec 随机游走方法从知识图谱中提取连接用户-课程对的连通子图,然后通过分层注意网络对子图进行编码,以生成用于用户所需课程预测的子图嵌入,最后生成 Top-N 推荐课程列表,并给出模型的可解释性说明。为验证模型的有效性,以“中国大学 MOOC(慕课)”上的数据为样本构建数据集,实验结果表明,相较于 KGCN-PN、GAT、KGAT 以及 POCR 模型,文中模型在 NDCG、HR 以及 MRR 评价指标上分别提升了 10.6%、9.41%、13.7%。

关键词:知识子图;分层注意机制;推荐系统;在线课程;随机游走

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2024)04-0139-07

doi:10.20165/j.cnki.ISSN1673-629X.2024.0021

An Online Course Recommendation Model Integrating Knowledge Subgraph and Attention Mechanism

WANG Shuo¹, GU Yi-ran^{1,2}, HUANG Li-ya³

(1. School of Automation & School of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

2. Center of Smart Campus Research, Nanjing University of Posts and Telecommunications, Nanjing 210023, China;

3. School of Electronic and Optical Engineering & Microelectronics, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: The recommendation system can help users filter out the items that meet their needs among the massive resources, and the evolving recommendation system provides new ideas for online education. As an important part of online education, online course resource recommendation currently has the problems of overload of course resources and lack of interpretability of course recommendation results. In this regard, we propose an online course recommendation model based on knowledge subgraph and attention mechanism to use knowledge subgraph for recommendation. Different from the model that directly uses the knowledge graph for recommendation and ignores the problem of inaccurate knowledge representation, the proposed model first uses the Node2vec random walk method to extract the connected subgraph connecting user-course pairs from the knowledge graph, and then encodes the subgraph through the hierarchical attention network to generate a subgraph embedding for the prediction of the courses required by the user. Finally, a list of Top-N recommended courses is generated, and an interpretability description of the proposed model is given. In order to verify the effectiveness of the proposed model, the data set on the "MOOC (MOOC) of Chinese universities" was used as the sample, and the experimental results show that compared with the KGCN-PN, GAT, KGAT and POCR, the proposed model improves the NDCG, HR and MRR evaluation indexes by 10.6%, 9.41% and 13.7%, respectively.

Key words: knowledge subgraph; hierarchical attention mechanism; recommendation system; online courses; random walk

收稿日期:2023-06-07

修回日期:2023-10-09

基金项目:国家自然科学基金资助项目(61977039)

作者简介:王 烁(1999-),男,硕士生,研究方向为推荐系统、深度学习;通信作者:顾亦然(1972-),女,教授,CCF 会员(E200012844M),研究方向为复杂网络、大数据处理。

0 引言

随着信息技术的发展,在线课程资源数量源源不断地增加,造成了“信息过载”“知识迷航”等现象。学习者面对海量的课程资源,难以在短时间内找到适合自己的学习课程,因此学习者的个性化推荐需求就愈发强烈。个性化推荐方法可以通过分析学习者的历史交互课程等数据对其个性化建模,并自动生成学习者所需课程,能够有效缓解在线课程资源过载问题,优化学习路径、提高学习效率。

目前,常用的课程资源推荐方法包括基于内容的推荐、基于知识的推荐以及混合推荐。基于内容的推荐方法通过计算学习者的偏好特征与学习资源的属性特征之间的偏差,寻找最符合学习者偏好的学习资源。Raj 等人^[1]将学习者偏好特征与学习资源特征按照特定规则相关联并计算相关性分数,最后根据得分进行排名。Shu 等人^[2]结合学习者偏好与课程资源文本数据进行推荐,并引入 Bregman 迭代方法对模型进行求解,极大地提高了训练效率。基于内容的推荐方法过度依赖学习资源的属性特征,当缺乏有效的数据特征时,该方法的推荐精度将大幅降低。

基于知识的推荐方法^[3]根据学习者在不同领域知识中的偏好向其推荐学习资源。Foteini 等人^[4]提出用本体对学习者的个人信息、认知信息、社会信息等。随着知识图谱的出现,Shi 等人^[5]提出了一个跨领域的知识图谱,其中包含学习对象之间的六种语义关系,根据学习者的目标生成个性化学习路径。混合推荐方法^[6]通过结合多种推荐方法来提高推荐准确率,在解决矩阵稀疏性、冷启动等问题上有不错的表现。文献[7]提出了一种增强型电子学习混合系统(enhanced e-learning hybrid recommender system, ELHRS),根据学习者的行为和语义矩阵中计算的语义关系,自适应地关联学习模式与规则,并将基于 CNN 的情感分析模型作为课程预测的一部分。Esteban 等人^[8]提出了一种融合协同过滤与遗传算法的混合推荐方法,该方法利用遗传算法优化参数配置,并构建推荐系统模型。Wan 等人^[9]将学习者影响模型与多种推荐策略结合起来,向学习者推荐学习资源。

随着研究的深入,越来越多的学者发现,不同的交互项目会对用户的偏好产生重要影响,因此,基于注意力机制的 GAT^[10](graph attention networks)算法应运而生,以更加准确地探索用户偏好的变化。随着图学习技术表征能力的加强,基于图学习的推荐算法逐渐流行。ItemRank^[11](a random-walk based scoring algorithm)和 HERec^[12](heterogeneous information

network embedding for recommendation)通过异构图表示算法,深入挖掘了“用户-项目”中的交互信息与用户偏好信息。Wang 等人^[13]提出了一种基于课程预训练的异构子图转换器,基于该转换器可以提取子图中丰富的语义信息。随后出现的图卷积技术,通过全新的邻居节点信息聚合编码机制,进一步提升了模型表征效果。Wang 等人^[14]提出了一种基于超边的图神经网络模型(hyperedge-based graph neural network, HGNN),将学习者表示的任务转化为超边的嵌入,同时考虑课程长、短期序列关系,利用 GNN 聚合课程信息,最终实现课程推荐。李世宝等人^[15]利用图卷积神经网络将知识图谱中的实体信息与接收域信息逐层融合,提出了一种基于共同邻居排序采样的知识图谱卷积网络(knowledge graph convolutional networks-public neighbors sorting, KG-CN-PN)推荐模型,较好地解决了数据稀疏性问题。Wang 等人^[16]提出了一种新的知识图注意网络(knowledge graph attention network for recommendation, KGAT),以端到端的方式对知识图谱中的高阶连通性进行显示建模。Yang 等人^[17]提出了一个双边知识图增强的在线课程推荐模型(POCR),以 KG 作为协同过滤的辅助信息源,并使用 KG 的端到端框架丰富语义信息。

然而,以上方法均是以用户偏好为主导的推荐方法,具有较低的可解释性。因为课程推荐除了要考虑用户与课程的点击、评论、评分等交互以外,更加需要注重的是在学习过程中知识的获取。班启敏等人^[18]提出了一个结合知识与性格的多任务学习框架,该框架将增强的知识追踪任务作为辅助任务去协助课程推荐任务,较好地解决了知识遗忘问题。文献[19]提出了一种基于图神经网络的推荐方法,不仅学习了“用户-课程”的直接交互信息,更探索了“用户-课程-知识”的间接知识关联,能够向用户推荐符合其用户画像的课程,具有较强的可解释性;但对用户-知识的交互仅采用 $\{0,1\}$ 矩阵表示,缺乏对知识交互信息的深度挖掘。

该文提出了一种基于知识子图与注意力机制的在线课程推荐模型,从知识图谱中抽取连接用户-课程对的连通子图,并引入分层注意力子图编码以学习子图嵌入,最终实现用户个性化课程推荐。

主要的研究工作如下:

(1)提出一种融合知识子图与注意力机制的在线课程推荐模型,并在真实的数据集上与基准模型在推荐性能方面进行比较。

(2)讨论超参数的不同设置对模型推荐结果的影响。

(3)对模型的推荐结果做可解释性说明。

1 系统模型

1.1 问题定义

对于给定的 m 个用户组成的集合 $U = \{u_1, u_2, \dots, u_m\}$ 以及 n 个课程组成的集合 $I = \{i_1, i_2, \dots, i_n\}$, 模型构建用户-课程交互矩阵 R 和用户-课程知识图谱 $G_{(u,i)}$, KSAM(course recommendation model integrating knowledge subgraph and attention mechanism) 通过聚合嵌入向量 $e_u, e_i, S_{(u,i)}$ 来量化用户 u 对课程 i 的偏好值, 从而完成用户潜在需求课程的预测。

1.2 模型框架

设计的 KSAM 模型如图 1 所示。模型由三个部分组成:

(1) 子图提取: 通过提取连接用户-课程对的知识子图来表示它们的连接性;

(2) 分层注意子图编码: 通过分层注意力嵌入学习过程对子图进行编码, 首先通过分层传播机制学习子图中实体的嵌入, 然后聚合实体嵌入, 导出子图嵌入;

(3) 课程预测: 利用用户-课程对的子图嵌入以及子图连通性来预测用户的所需课程。

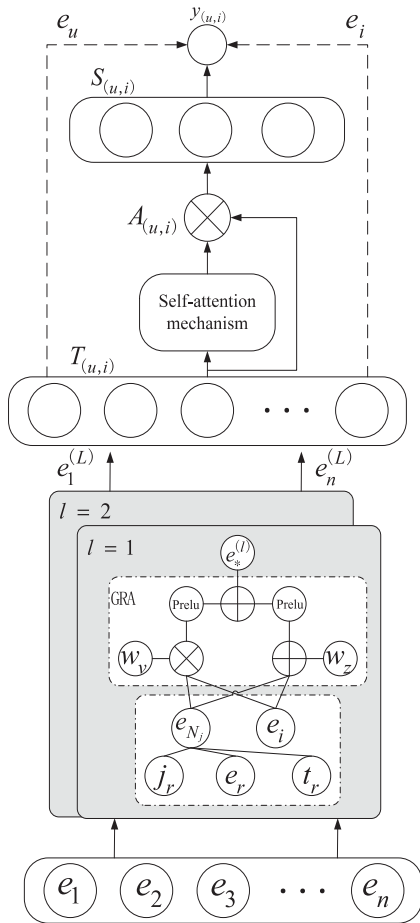


图 1 KSAM 框架结构

1.3 子图提取

传统的图挖掘方法无法实现有效的子图提取, 该

文将图挖掘转化为路径采样, 通过提取用户-课程对之间的路径构建子图。

1.3.1 路径采样

由于路径的数量随着路径长度的增加呈指数增长, 想要从用户-课程知识图谱中提取出用户-课程对之间的所有路径是不可行的。实际上, 长度较短 (不超过 6) 的路径足以证明模型用户-项目的连通性, 而长路径可能会带来远程邻居的噪音。为提高效率、减小噪音, 该文采用 Node2vec 随机游走的方法^[20]生成一组采样路径, 并将该路径集合记为 $\mathcal{L}_{(u,i)}$ 。具体地, 对于用户-课程知识图谱 $G_{(u,i)}$, 随机选定节点 S_1 , 从 S_1 出发开始长度为 6 的随机游走, 如图 2 所示, 节点 S_{K-2} 游走到 S_{K-1} , 而 S_{K-1} 下一步的游走概率为:

$$P(K|K-1) = \alpha \times \frac{\omega(K-1, K)}{\sum_{v \in Q(K-1)} \omega(K-1, v)} \quad (1)$$

其中, α 为二阶随机游走参数; $\omega(K-1, K)$ 为节点 $K-1, K$ 连边的权重值; v 为与 S_{K-1} 节点有连边的节点。




图 2 游走示意图

1.3.2 路径集合

通过随机组合 $\mathcal{L}_{(u,i)}$ 中的 P 条采样路径, 生成用户-课程知识图谱的子图 $g_{(u,i)}$, 再将 $g_{(u,i)}$ 中的节点与连边映射为实体和关系。此时, $g_{(u,i)}$ 中囊括了用户-课程知识图谱中的实体、实体类型和关系等语义信息。然后将 $g_{(u,i)}$ 输入分层注意子图编码模块, 学习用于表征用户-课程连通性的子图嵌入。

1.4 分层注意子图编码

分层注意子图编码学习子图嵌入信息, 来更好地表示用户-课程的连通性。该过程包含两个核心步骤:

(1) 实体嵌入学习: 通过分层传播机制对子图中的实体嵌入;

(2) 子图嵌入学习: 聚合实体嵌入, 得到子图嵌入。

1.4.1 实体嵌入学习

利用分层传播机制, 根据邻居传播的语义更新实体嵌入, 并多层叠加以利用高阶子图拓扑结构。该部

分先讨论单层实体嵌入,再推广至多层。

单层结构:

对于每个可能包含多种属性与关系的实体,用 $N_j = \{(j, r, t) | (j, r, t) \in G_{(u,i)}\}$ 表示以头实体为 j 的三元组集合。鉴于不同属性对头实体的贡献度不同,此部分利用 GRA 函数为其分配不同的权重,并依据与邻居节点的交互构建实体 j 的一阶连通性表达,即:

$$e_{N_j} = \sum_{(j,r,t) \in N_j} \text{GRA}(j, r, t) \cdot e_t \quad (2)$$

在得到 e_{N_j} 的表示后,采用多通道融合函数聚合实体 j 及其邻域节点信息。通过累加实体 j 和邻域节点信息来增强实体特征信号。为避免 e_{N_j} 和 e_j 的相似特征在融合后被削弱,通过按位操作,减少噪声对信号融合时产生的影响,即:

$$\begin{aligned} f(e_j, e_{N_j}) &= \text{prelu}[X_1 + X_2] \\ X_1 &= \mathbf{W}_Z(e_{N_j} + e_{h_j}) \\ X_2 &= \mathbf{W}_V(e_{N_j} \otimes e_j) \end{aligned} \quad (3)$$

其中, Prelu 为非线性激活函数; \otimes 表示按元素相乘; $\mathbf{W}_Z, \mathbf{W}_V$ 为可训练权重矩阵。

多层结构:

为得到节点的高阶连通性,此部分通过叠加传播层来收集高阶实体传播信息。对于第 l 层节点 j 的嵌入表示为:

$$e_j^{(l)} = f(e_j^{(l-1)}, e_{N_j}^{(l-1)}) \quad (4)$$

其中, $e_j^{(l-1)}$ 为 $l-1$ 层节点 j 的表示;邻居节点聚合信息 $e_{N_j}^{(l-1)}$ 表示如下:

$$e_{N_j}^{(l-1)} = \sum_{(j,r,t) \in N_j} \text{GRA}(j, r, t) \cdot e_t^{(l-1)} \quad (5)$$

在堆叠 L 层后, e_j 的嵌入形式表示为:

$$\begin{aligned} e_j &= e_j^{(L)} \\ \forall e_j &\in g(u, i) \end{aligned} \quad (6)$$

其中, $e_j^{(L)}$ 为最终传播层 L 输出的实体嵌入。进一步地,子图 $g_{(u,i)}$ 的实体嵌入矩阵表示为:

$$\mathbf{T}_{(u,i)} = [e_1, e_2, \dots, e_n] \quad (7)$$

之后,将实体嵌入矩阵 $\mathbf{T}_{(u,i)}$ 输入子图嵌入学习模块,以生成 $g_{(u,i)}$ 的整体子图嵌入。

1.4.2 子图嵌入学习

子图嵌入学习通过聚合实体嵌入来生成子图嵌入,其中使用自注意力机制来区分子图中各实体的重要性,以增强嵌入学习。

对于具有 n 个实体的子图 $g_{(u,i)}$,自注意力机制以实体嵌入矩阵 $\mathbf{T}_{(u,i)}$ 为输入并通过注意力网络输出 $g_{(u,i)}$ 中各实体的重要性,公式表达为:

$$\boldsymbol{\alpha}_{(u,i)} = \text{softmax}(w_2 \cdot \tanh(\mathbf{W}_1 \mathbf{T}_{(u,i)}^T)) \quad (8)$$

其中, \mathbf{W}_1 和 w_2 是注意力网络的可训练权重矩阵和权重向量;并且 $\boldsymbol{\alpha}_{(u,i)}$ 是 $g_{(u,i)}$ 中所有实体的注意力得分

的向量,并通过 softmax 函数归一化。为获取子图整体语义,将等式 8 中的注意力网络扩展为多头注意力,具体表示为:

$$\mathbf{A}_{(u,i)} = \text{softmax}(\mathbf{W}_2 \cdot \tanh(\mathbf{W}_1 \mathbf{T}_{(u,i)}^T)) \quad (9)$$

其中, \mathbf{W}_2 是可训练权重矩阵; $\mathbf{A}_{(u,i)}$ 是注意力得分矩阵。基于注意力得分矩阵 $\mathbf{A}_{(u,i)}$, $g_{(u,i)}$ 的子图嵌入表示如下:

$$s_{(u,i)} = f_g(\mathbf{A}_{(u,i)}, \mathbf{H}_{(u,i)}) \quad (10)$$

1.5 课程预测

该文综合用户嵌入 e_u 、课程嵌入 e_i 以及整体子图嵌入 $S_{(u,i)}$ 以实现课程预测,具体表示为:

$$\bar{y}_{(u,i)} = \text{MLP}([e_u, S_{(u,i)}, e_i]) \quad (11)$$

其中, $\bar{y}_{(u,i)}$ 是用户 u 对课程 i 的估计排名分数。在等式 11 中,将三个嵌入的串联向量反馈至多层感知器来生成预测。采 ReLU 函数作为隐藏层激活函数,采用 sigmoid 函数作为输出层的激活函数以控制排名分数 $\bar{y}_{(u,i)}$ 在 $[0, 1]$ 内。

2 实验结果与分析

2.1 实验数据集

文中的数据集为通过网络爬取技术采集“中国大学 MOOC(慕课)^[21]”上的课程,涉及的课程类别包括计算机、化学、物理、航空航天等 15 个门类。采集的课程信息包括课程名称、作者、方向、类型、关键词等内容。具体内容如表 1 所示。

表 1 数据集

关系名称	关系描述	关系数量
作者	(课名, 作者, 作者)	2 048
属于	(课名, 属于, 方向)	2 048
类型	(课名, 类型, 类型)	2 048
包含	(课名, 包含, 关键词)	11 578
发布	(课名, 发布, 时间)	2 048
评分	(课名, 评分, 评分)	2 048

同时将课程数据集中各类节点与关系存储至 Neo4j 中,构建完整的课程知识图谱,部分知识图谱如图 3 所示。

2.2 基准模型

将该文提出的模型与多种课程推荐模型进行了实验结果的对比,包括基于神经网络的推荐模型(KGCN-PN^[16])、图神经网络与注意力结合的推荐模型(GAT^[10])、图注意力网络与知识图谱结合的推荐模型(KGAT^[17])以及双边知识图增强的在线课程推荐模型(POCR^[18])。

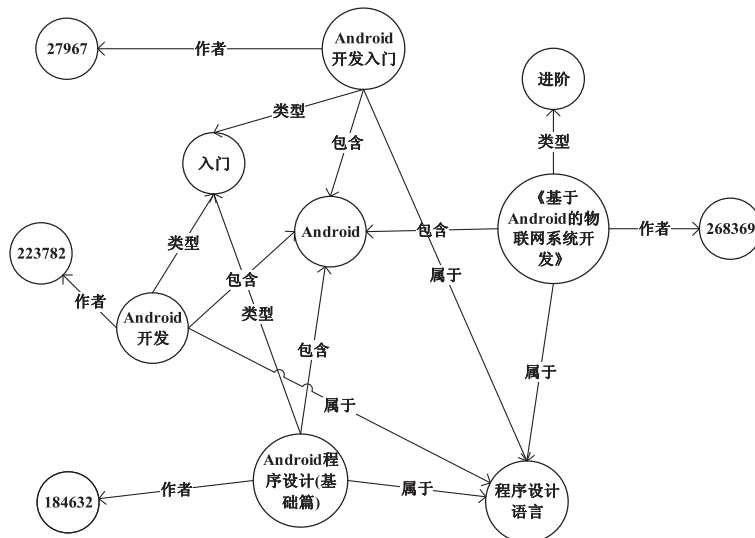


图3 部分知识图谱示意图

2.3 评价指标

在实验中,选取 $NDCG@N$ 、 $HR@N$ 以及 $MRR@N$ 作为推荐结果的评估指标。

(1) $NDCG@N$ 。

$NDCG$ (normalized discounted cumulative gain) 为归一化折损累计增益,是一种衡量排名质量的评价指标,通常用来验证推荐列表的合理性。

(2) $MRR@N$ 。

MRR (mean reciprocal ranking) 反映了正样本在推荐列表中的排名。

(3) $HR@N$ 。

HR (hit ratio) 是指在链接预测中排名小于等于 N 的三元组的平均占比,反映了推荐结果的准确性。

2.4 模型对比结果分析

在 $Top-N$ 推荐中, N 表示在推荐列表中的前 N 个

推荐课程。实验结果如表2所示,以推荐课程数量等于15为例,文中推荐模型在3个评价指标上表现出了最好的推荐效果,其次为 $KGAT$ 模型。基于 $Top-N$ 推荐测评, $KSAM$ 较 $KGAT$ 有明显的提升,其中在 $NDCG$, HR , MRR 上分别提升了 10.6%, 9.41%, 13.7%。

$KSAM$ 模型在各项指标中表现出最优的性能,得益于:

(1) 采用 $Node2vec$ 提取的子图在表征用户-课程连通性方面的优异表现力。

(2) 分层注意嵌入学习过程在编码子图以揭示用户需求课程方面的有效性,使得模型能够捕获丰富的语义信息,从而产生符合用户需求的推荐结果。

表2 不同模型指标对比

模型	NDCG			HR			MRR		
	@ 5	@ 10	@ 15	@ 5	@ 10	@ 15	@ 5	@ 10	@ 15
KGCN-PN	0.557	0.627	0.645	0.692	0.779	0.797	0.291	0.389	0.427
GAT	0.499	0.577	0.621	0.681	0.752	0.785	0.258	0.351	0.386
KGAT	0.581	0.631	0.658	0.711	0.769	0.818	0.355	0.457	0.497
POCR	0.574	0.619	0.645	0.697	0.787	0.804	0.322	0.419	0.451
KSAM	0.635	0.694	0.728	0.775	0.812	0.895	0.441	0.511	0.565

2.5 超参数设置

此部分研究了 $KSAM$ 模型的代表性超参数,包括采样路径的数量 P 以及传播层数 L 。

2.5.1 采样路径数量

基于知识图谱的课程推荐精度与采样路径数量密不可分,该论文在 $\{5, 10, 15, 20, 25\}$ 的限定范围内不断调整采样路径的数量 P ,以测试其对推荐精度的影响。如图4所示,随着采样路径数量的增加,推荐精度

也随之提高,并在 $P = 20$ 时达到最优,而随着 P 的进一步增加,推荐精度逐渐下降。这代表着过多的路径数量会引入噪声,降低 $KSAM$ 的推荐性能。

2.5.2 传播层数

文中模型在实体嵌入过程中引入了分层传播机制,为了研究不同传播层数对推荐精度的影响,此部分以传播层 L 为变量, $L = \{0, 1, 2, 3, 4\}$ 。实验结果如图5所示。 $KSAM$ 在 $L = 2$ 时表现出的性能优于 $L = 0, 1$

时,这是因为随着传播层数的增加,更易获取节点间的高阶信息。当堆叠的传播层继续增加时($L=3,4$),模型性能反而持续下降,这表明各实体间的二阶关系足以捕获子图的语义信息,过多地堆叠传播层可能会产生过拟合问题。




图4 采样路径数量




图5 传播层数

2.6 可解释性说明

该文基于用户-课程的知识子图进行推荐,更加注重各实体间的有效连通性,并最大程度地减小与特定用户项连通性无关的噪声。

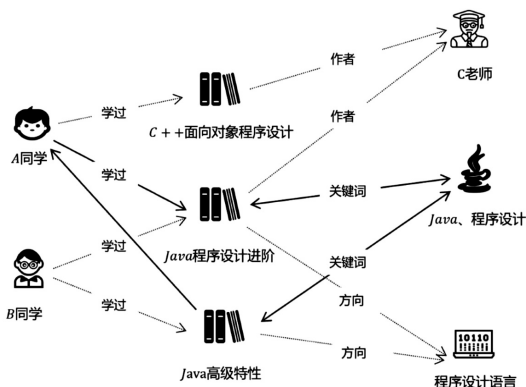


图6 课程推荐知识图

如图6所示,B同学学过《Java高级特性》这门课,

且该门课程包含“Java、程序设计”关键词,课程方向为“程序语言设计”。当实体对邻居节点进行注意力权重计算时,《Java高级特性》(头节点)加方向(关系)未必能准确预测为“程序语言设计”(尾节点)。为了避免NAM知识嵌入方法对《Java高级特性》预测的尾节点和“程序语言设计”节点存在的偏差对注意力权重产生影响,对其进行偏差处理操作。同时,A同学和B同学均学过《Java程序设计进阶》,且该课程与《Java高级特性》在关键词、方向上具有相似性,因此,将《Java高级特性》推荐给A同学。综上,该文提出的KSAM模型具有较强的可解释性。

3 结束语

该文提出了一种融合知识子图与注意力机制的课程推荐模型,通过构建用户-课程对子图,以表征它们的连通性,并设计了分层注意嵌入学习过程来有效地编码子图。在真实的数据集上进行的对比实验证明了KSAM的合理性与有效性。后续的工作考虑将时间因素纳入到知识图谱中。由于用户所需课程通常会随着时间的推移而演变,可能会受到动态用户偏好、流行度等因素的影响,而时间因素被认为是对动态用户偏好建模的关键信息。因此,接下来希望通过将时间因素纳入知识图谱来调整所提出的KSAM模型,以进行更有效的动态推荐。

参考文献:

- [1] RAJ N S, RENUMOL V G. A rule-based approach for adaptive content recommendation in a personalized learning environment: an experimental analysis[C]//2019 IEEE tenth international conference on technology for education (T4E). Goa: IEEE, 2019: 138-141.
- [2] SHU J, SHEN X, LIU H, et al. A content-based recommendation algorithm for learning resources[J]. Multimedia Systems, 2018, 24(2): 163-173.
- [3] TARUS J K, NIU Z, MUSTAFA G. Knowledge-based recommendation: a review of ontology-based recommender systems for e-learning[J]. Artificial Intelligence Review, 2018, 50: 21-48.
- [4] GRIVOKOSTOPOULOU F, PERIKOS I, PARASKEVAS M, et al. An ontology-based approach for user modelling and personalization in E-learning systems[C]//2019 IEEE/ACIS 18th international conference on computer and information science (ICIS). Seattle: IEEE, 2019: 1-6.
- [5] SHI D, WANG T, XING H, et al. A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning[J]. Knowledge-Based Systems, 2020, 195: 105618.
- [6] REN Y, HE Z, HAN T. Research on optimal design of online

- education course recommendation system based on hybrid recommendation algorithm[C]//2021 2nd international conference on big data and informatization education (ICBDIE). Hangzhou: IEEE, 2021: 461–464.
- [7] EZALDEEN H, MISRA R, BISOY S K, et al. A hybrid E-learning recommendation integrating adaptive profiling and sentiment analysis[J]. *Journal of Web Semantics*, 2022, 72: 100700.
- [8] ESTEBAN A, ZAFRA A, ROMERO C. Helping university students to choose elective courses by using a hybrid multi-criteria recommendation system with genetic optimization[J]. *Knowledge-Based Systems*, 2020, 194: 105385.
- [9] WAN S, NIU Z. A hybrid e-learning recommendation approach based on learners' influence propagation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 32(5): 827–840.
- [10] VELIĆKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. *arXiv*:1710.10903, 2017.
- [11] GORI M, PUCCI A. ItemRank: a random-walk based scoring algorithm for recommender engines[C]//Proceedings of the 20th international joint conference on artificial intelligence. Hyderabad: Springer, 2007: 2766–2771.
- [12] SHI C, HU B, ZHAO W X, et al. Heterogeneous information network embedding for recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 31(2): 357–370.
- [13] WANG H, ZHOU K, ZHAO X, et al. Curriculum pre-training heterogeneous subgraph transformer for top-N recommendation[J]. *ACM Transactions on Information Systems*, 2023, 41(1): 1–28.
- [14] WANG X, MA W, GUO L, et al. Hgmn: hyperedge-based graph neural network for mooc course recommendation[J]. *Information Processing & Management*, 2022, 59(3): 102938.
- [15] 李世宝, 张益维, 刘建航, 等. 基于知识图谱共同邻居排序采样的推荐模型[J]. *电子与信息学报*, 2021, 43(12): 3522–3529.
- [16] 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. Anchorage: ACM, 2019: 950–958.
- [17] YANG S, CAI X. Bilateral knowledge graph enhanced online course recommendation[J]. *Information Systems*, 2022, 107: 102000.
- [18] 班启敏, 吴 雯, 胡文心, 等. 基于学习者知识和性格的个性化课程推荐[J]. *华东师范大学学报: 自然科学版*, 2022(6): 87–101.
- [19] GONG J, WANG S, WANG J, et al. Attentional graph convolutional networks for knowledge concept recommendation in moocs in a heterogeneous view[C]//Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval. New York: ACM, 2020: 79–88.
- [20] 卢春华, 胡晓楠, 彭璐康, 等. 融合网络和文本特征的智能课程推荐方法[J]. *计算机应用与软件*, 2023, 40(2): 74–81.
- [21] WANG X, MA W, GUO L, et al. HGNN: hyperedge-based graph neural network for MOOC course recommendation[J]. *Information Processing & Management*, 2022, 59(3): 102938.