

基于静态与动态学习需求感知的知识点推荐方法*

周洋涛, 李青山, 褚华, 李佳楠, 高明彪, 卫彪彪



(西安电子科技大学 计算机科学与技术学院, 陕西 西安 710071)

通信作者: 褚华, E-mail: hchu@mail.xidian.edu.cn

摘要: 随着互联网信息技术的高速发展, 线上学习资源的爆炸式增长引起了“信息过载”与“学习迷航”问题。在缺乏专家指导的场景中, 用户难以明确自己的学习需求并从海量的学习资源中选择合适的内容进行学习。教育领域推荐方法能够基于用户的历史学习行为提供学习资源的个性化推荐, 因此该方法近年来受到大量研究人员的广泛关注。然而, 现有的教育领域推荐方法在学习需求感知时忽略了对知识点之间复杂关系的建模, 同时缺乏考虑用户学习需求的动态性变化, 导致推荐的学习资源不够精准。针对上述问题, 提出一种基于静态与动态学习需求感知的知识点推荐方法, 通过静态感知与动态感知相结合的方式建模复杂知识关联下的用户学习行为。对于静态学习需求感知, 设计一种基于知识点先修后继元路径引导的注意力图卷积网络, 通过建模知识点之间先修后继关系的复杂约束, 能够消除其他非学习需求因素的干扰, 从而精准地捕获用户在细粒度知识点层面上的静态学习需求; 对于动态学习需求感知, 所提方法以课程为单元聚合知识点嵌入以表征用户在不同时刻的知识水平, 然后采用循环神经网络建模编码用户的知识水平序列, 能够有效地挖掘用户知识水平变化中蕴含的动态学习需求; 最后, 对获得的静态与动态学习需求进行融合, 在同一框架下建模静态与动态学习需求之间的兼容性, 促进这两种学习需求相互补充, 以实现细粒度的个性化知识点推荐。实验表明, 在两个公开数据集上, 所提方法能够有效地感知用户的学习需求并提供个性化的知识点推荐, 在多种评估指标上优于主流的推荐方法。

关键词: 知识点推荐; 知识感知; 动态性建模; 学习需求融合

中图法分类号: TP311

中文引用格式: 周洋涛, 李青山, 褚华, 李佳楠, 高明彪, 卫彪彪. 基于静态与动态学习需求感知的知识点推荐方法. 软件学报, 2024, 35(9): 4425–4447. <http://www.jos.org.cn/1000-9825/6962.htm>

英文引用格式: Zhou YT, Li QS, Chu H, Li JN, Gao MB, Wei BB. Knowledge Point Recommendation Method Based on Static and Dynamic Learning Demand Perception. Ruan Jian Xue Bao/Journal of Software, 2024, 35(9): 4425–4447 (in Chinese). <http://www.jos.org.cn/1000-9825/6962.htm>

Knowledge Point Recommendation Method Based on Static and Dynamic Learning Demand Perception

ZHOU Yang-Tao, LI Qing-Shan, CHU Hua, LI Jia-Nan, GAO Ming-Biao, WEI Biao-Biao

(School of Computer Science and Technology, Xidian University, Xi'an 710071, China)

Abstract: With the rapid development of Internet information technologies, the explosive growth of online learning resources has caused the problem of “information overload” and “learning disorientation”. In the absence of expert guidance, it is difficult for users to identify their learning demands and select the appropriate content from the vast amount of learning resources. Educational domain recommendation methods have received a lot of attention from researchers in recent years because they can provide personalized recommendations of learning resources based on the historical learning behaviors of users. However, the existing educational domain recommendation methods ignore the modeling of complex relationships among knowledge points in learning demand perception and fail to consider the dynamic

* 基金项目: 国家自然科学基金 (61972300, U21B2015, 62202356); 陕西省科协青年人才托举计划 (20220113); 西安电子科技大学智慧金融软件工程新技术联合实验室项目 (99901220858)

收稿时间: 2022-07-09; 修改时间: 2023-02-15; 采用时间: 2023-05-02; jos 在线出版时间: 2023-08-30

CNKI 网络首发时间: 2023-08-31

changes of users' learning demands, which leads to inaccurate learning resource recommendations. To address the above problems, this study proposes a knowledge point recommendation method based on static and dynamic learning demand perception, which models users' learning behaviors under complex knowledge association by combining static perception and dynamic perception. For static learning demand perception, this study innovatively designs an attentional graph convolutional network based on the first-course-following meta-path guidance of knowledge points, which can accurately capture users' static learning demands at the fine-grained knowledge point level by modeling the complex constraints of the first-course-following relationship between knowledge points and eliminating the interference of other non-learning demand factors. For dynamic learning demand perception, the method aggregates knowledge point embeddings to characterize users' knowledge levels at different moments by taking courses as units and then uses a recurrent neural network to encode users' knowledge level sequences, which can effectively explore the dynamic learning demands hidden in users' knowledge level changes. Finally, this study fuses the obtained static and dynamic learning demands, models the compatibility between static and dynamic learning demands in the same framework, and promotes the complementarity of these two learning demands to achieve fine-grained and personalized knowledge point recommendations. Experiments show that the proposed method can effectively perceive users' learning demands, provide personalized knowledge point recommendations on two publicly available datasets, and outperform the mainstream recommendation methods in terms of various evaluation metrics.

Key words: knowledge point recommendation; knowledge perception; dynamicity modeling; learning demand integration

自互联网时代以来,信息技术的高速发展引领了新一轮的教育变革,传统的线下教育模式正逐步向在线智慧教育转型。在线学习已经成为用户学习知识的重要途径之一,通过在线学习的方式,用户可以不用受限于时间碎片化以及空间约束问题^[1],能够随时随地进行学习。然而,在线学习平台中学习资源的丰富带来了“信息过载”与“学习迷航”问题。一方面,在“信息过载”问题下,在线学习平台上的学习资源繁多且良莠不齐,用户无从选择;另一方面,“学习迷航”问题是指在线学习平台缺乏专家的专业指导与课程规划,学生容易迷失其中并导致学习失败。因此,如何深入探索教育领域的推荐场景特点,促进推荐系统在教育领域中的有效应用,是目前亟待解决的研究问题。

目前,大量在线学习平台纷纷推出智能推荐功能,为用户提供个性化的学习资源推荐,以提高用户的学习效果。这些平台中的教育推荐模型借鉴了电商或多媒体领域中的推荐流程,主要围绕如何精准地挖掘用户-学习资源交互中蕴含的用户兴趣偏好以进行针对兴趣的推荐预测^[2-4]。其基本流程可划分为两个步骤:首先基于用户与学习资源的历史学习行为数据进行用户兴趣画像挖掘,捕获用户对学习资源的兴趣偏好特征;然后再基于构建的用户兴趣画像采用向量点积或神经网络特征交叉等方式进行学习资源推荐结果的预测计算。

然而,教育领域中的推荐有不同于其他领域的特征。第一,有别于其他应用场景中待推荐对象类型单一的特点,教育推荐场景中存在多种待推荐的学习资源,如课程、视频以及知识点等。同时,学习资源之间存在多种类型的关联关系,如课程与知识点之间存在包含关系、知识点之间存在先修后继关系等。学习资源类型的多样性及其关联关系的多样性共同呈现出显著的知识关联复杂性。第二,教育推荐场景中的用户是学习者,其目的在于通过学习获取或掌握资源中的知识点,完成特定的学习目标,进而实现其个人学习需求。用户的学习需求受到学习资源之间多种复杂关联关系的约束,如先修后继关系等。若模型推荐的结果不满足用户的实际学习需求,特别是不满足知识点先修后继关系的约束,即出现缺乏学习基础知识便开始学习高阶知识的情况,则很容易导致“学习失败”问题。因此,如何有效地建模学习资源之间的复杂关联关系、对用户的学习需求进行深入挖掘,是教育领域推荐系统面临的关键挑战。

近年来,开始有学者尝试探索对学习资源的复杂关联与用户的学习需求进行建模。这些研究工作^[4-8]将课程类别知识或实体关联知识等作为边信息(side information)补充到深度学习推荐模型的输入中,以丰富模型的输入特征并辅助用户画像的挖掘。然而,这些方法存在两方面的不足。一方面,受学习需求驱动的用户学习行为需要满足知识点之间的复杂关联关系约束,而现有的方法仅在模型输入时采用边信息的方式补充知识关系,所建模的知识点关系隐式且单一,对用户学习需求的挖掘能力有限。另一方面,用户的学习需求在用户的学习过程中会随着用户自身知识水平的提升而动态变化,现有的方法直接对用户所有的历史学习行为进行建模,缺乏考虑用户学习需求的动态特性。

针对上述问题,本文提出了一种基于静态与动态学习需求感知的知识点推荐方法。该方法可以直接地对知识点之间的先修后继关系进行建模,显式地挖掘用户潜在的静态学习需求,并且可以编码用户在不同时刻的知识水

平, 建模用户学习需求的动态变化。该方法中的核心构件主要包括静态学习需求建模模块以及动态学习需求建模模块。为了显式地建模用户的学习需求, 本文在静态学习需求建模模块中对知识点之间的复杂关联关系进行显式建模, 如先修后继关系等, 以引导学习需求的感知过程, 挖掘用户在更细粒度的知识点层面上的静态学习需求; 为了捕获用户学习需求的动态变化, 本文首先对用户每阶段的知识水平进行编码表示, 然后采用循环神经网络对用户不同阶段的知识水平进行序列化建模, 以捕获用户知识水平的动态变化, 提取出用户随知识水平动态变化的动态学习需求。本文所提的方法可以精准地捕获用户的学习需求, 提供个性化知识点推荐, 主要贡献点如下。

(1) 整体上, 提出了一种基于静态与动态学习需求感知的知识点推荐方法。与现有的教育推荐方法不同, 该方法在一个统一的框架中同时集成与融合图卷积网络和循环神经网络, 提供更细粒度且实时动态的学习需求建模方式, 既考虑了知识点之间的复杂关联关系, 又能感知用户学习需求的动态性变化, 有效地保证了推荐结果的合理性和准确性。

(2) 在静态学习需求建模上, 采用基于元路径(特别是先修后继知识元路径)的图卷积深度学习算法显式地建模实体之间复杂的关联关系, 从用户所有历史学习行为中感知用户在细粒度的知识点层面上的学习需求, 为后续推荐结果预测提供静态学习需求引导。

(3) 在动态学习需求建模上, 提出一种以课程为单位的知识水平建模的方式, 并采用循环神经网络建模用户在不同时间阶段下知识水平的动态变化, 感知用户在下一时刻的动态学习需求, 为后续推荐结果预测提供动态学习需求引导。

(4) 在模型验证上, 在真实教育学习的公开数据集 MOOCCube 上设计了综合的对比实验, 实验结果证明了该模型在教育领域推荐场景中的有效性。

本文第 1 节介绍与本文方法相关的工作。第 2 节介绍本文的研究动机。在第 3 节中对本文提出的基于静态与动态学习需求感知的知识点推荐方法进行详细介绍。第 4 节通过在公开 MOOC 数据集上进行对比实验验证了所提方法的有效性。最后总结全文并进行展望。

1 相关工作

1.1 推荐系统发展

在信息互联的时代, 用户面临的“信息过载”问题日益严重, 推荐系统作为有效解决“信息过载”问题的新兴技术近年来受到广泛关注、研究与应用。现有的推荐技术大致上可划分为传统的推荐技术与深度学习推荐技术两类。本节将对这两类推荐技术进行概述, 并补充对与本文建模方式最相关的基于异构信息网络的图卷积推荐方法的介绍。

1.1.1 传统的推荐技术

传统的推荐技术主要包括以协同过滤推荐算法为代表的一系列机器学习方法, 最早源于 1992 年 Goldberg 等人^[9]提出的基于用户的协同过滤推荐算法。该算法主要通过对用户-物品交互数据进行最近邻建模, 挖掘出与目标用户兴趣偏好相似的用户群体, 最后基于相似用户群体的偏好物品为目标用户提供推荐。2003 年, Amazon 研究团队^[10]从物品的角度出发提出了基于物品的协同过滤推荐技术。与基于用户的协同过滤相反, 基于物品的协同过滤推荐算法基于用户-物品交互数据提取出与目标物品最相似的物品群体, 然后将这些相似物品推荐给目标用户, 有效解决了基于用户的协同过滤推荐算法面临的可扩展性问题, 成为信息产业界应用最广泛的技术。后来, 针对协同过滤算法在应用过程中显现出来的头部效应明显与泛化能力弱的问题, Koren 等人提出矩阵分解推荐模型^[11]。该算法通过将协同过滤算法中的共现矩阵进行分解以获得用户与物品的隐向量, 最后基于用户与物品隐向量的内积以获得推荐结果。矩阵分解过程中获得的隐向量是基于全局信息生成的, 因此具有更强的泛化能力。传统的推荐技术在时间长流中不断积累与演化, 为深度学习推荐技术的发展与应用奠定了坚实的理论与实践基础。

1.1.2 深度学习推荐技术

近年来, 随着深度学习方法的高速发展以及在图像识别与自然语言处理等领域的成熟应用, 深度学习方法逐

渐被引荐到推荐系统中以促进推荐效果的提升。相较于传统的基于机器学习的推荐技术，深度学习方法具备更强的表达能力以及更加精巧的模型结构，可有效挖掘数据中潜在的特征并更好地契合应用场景^[12]。2017年，He等人提出了一种基于深度学习的协同过滤推荐模型 NeuralCF^[13]，该模型采用多层感知机结构替换矩阵分解模型中的隐向量内积操作，通过多层感知机的非线性特征交叉能力以获得更优的模型表示。但由于 NeuralCF 模型的核心思想为协同过滤，仅对用户 ID 与物品 ID 进行建模，缺乏引入更多其他类型的特征信息。*van den Berg* 等人^[14]将推荐问题转换为二部图上的链路预测问题，采用图自编码器实现推荐预测并将额外的特征信息作为边信息补充到模型中，取得了比 NeuralCF 模型更优的推荐效果。到 2020 年，LightGCN 轻量级图卷积推荐模型^[15]的提出，证明了原始的图卷积网络中的特征转换与非线性激活构件的存在会导致推荐性能的下降。除了图卷积网络外，注意力机制也被引进推荐系统中以挖掘对用户兴趣偏好贡献程度更大的物品特征。阿里巴巴研究团队于 2018 年提出的 DIN 模型^[16]采用了注意力机制提取对后续推荐结果影响更大的已交互物品，模拟人类在真实购物时的注意力思考过程，进而获得了更加准确的用户兴趣画像。由于上述的方法仅能挖掘用户的全局静态偏好，缺乏考虑用户兴趣的动态性，于是阿里巴巴研究团队在 DIN 模型的基础上提出 DIEN 模型^[17]，采用循环神经网络模型建模用户的兴趣进化过程，最终预测用户在下一时刻的购物兴趣。后来，MGNM 模型的提出^[18]深入探索驱动用户交互行为的多种潜在兴趣，通过多兴趣学习与序列化建模以提供下一时刻的候选物品推荐。更深入地，Chen 等人指出现有方法在训练数据采样上存在的不足，并设计了 3 种针对完整的训练数据进行训练学习的新的优化方法，最终提出了一种不需要采样的高效的神经矩阵分解模型 ENMF^[19]。除了采样方式，Mao 等人致力于探索更优的损失函数设计的研究，提出了一种新的余弦对比损失函数，旨在最大化正样本对之间的相似性，最小化边距约束下的负样本的相似性，并基于该损失函数提出了一种新的协同过滤推荐模型 SimpleX^[20]。总而言之，深度学习推荐技术凭借自身强大的建模与表达能力已经成为推荐系统在各个领域应用中的主流。

然而，现有的深度学习推荐方法广泛应用于发展多年的电商与新媒体等领域中，教育领域中的深度学习推荐技术直接搬用其他领域的推荐技术。忽略了教育推荐场景的特征。具体地，教育推荐方法的关键挑战在于如何有效地建模学习资源之间的复杂关联关系、对用户的学习需求进行深入挖掘，从而为用户提供满足其学习需求的个性化推荐。其中，用户的学习需求是异常复杂的，其复杂性体现在两个方面。一方面，在用户的历史交互行为中蕴含着用户的静态学习需求，该需求受到学习资源之间多种关联关系的约束，特别是知识点之间的先修后继关系；另一方面，在不同时刻下用户的学习需求是动态变化的，且与用户在不同时刻下的知识水平有关。而现有的通用推荐方法没有同时考虑静态和动态学习需求的感知，并且在对静态学习需求进行建模时忽略了对多种学习资源之间复杂的关联关系进行挖掘，尤其是对学习需求感知具有重要影响的先修后继关系；此外，现有的通用推荐方法也忽略了对用户在不同时刻的知识水平进行建模，更无法感知蕴含在用户知识水平序列变化中的动态学习需求。可见现有的教育领域推荐技术研究仍不够完善，尚处于研究的起步阶段。

1.1.3 基于异构信息网络的图卷积推荐方法

在真实场景中，图式数据通常是异构的，即存在多种类型的节点，如电商场景中的用户、物品与商铺等。相较于简单的用户-物品二部图，这种由多种不同类型节点构成的异构信息网络由于蕴含着更全面的结构信息和丰富的语义关联，近年来逐渐受到大量的研究关注。*Shi* 等人^[21]提出基于元路径的随机游走方法，将异构信息网络转换为带有元路径语义的节点序列，以获得更丰富的节点表征。*Wang* 等人^[22]指出有的基于异构信息网络的方法总是在每个元路径下孤立地对用户-物品进行建模，可能存在噪声问题。于是他们提出了 HueRec 方法，将用户、物品和元路径都嵌入到相关的嵌入空间中，使用所有的元路径以学习统一的用户和物品表征。虽然 HueRec 方法中提到了不同元路径之间存在公共的语义，但该方法只将所有元路径下的语义表征进行统一，而没有对元路径的不同重要性程度进行建模。为了解决元路径之间的关联关系缺乏显式建模的问题，*Gong* 等人^[7]将基于元路径引导的图卷积推荐方法引入到教育推荐场景中提出了 ACKRec 模型，并设计了一种元路径级的注意力机制，将不同元路径引导下获得的节点表征进行注意力聚合，从而显式地建模不同元路径之间的语义影响。*Gong* 等人通过充分的对比实验，验证了他们提出的 ACKRec 模型击败了一系列主流的基于异构信息网络的图卷积推荐方法，取得了优越的知识点推荐效果。虽然 ACKRec 探索了不同元路径对推荐效果的影响并选取了最优的元路径集合以提供推荐，但

其忽略了教育场景中对用户学习效果具有关键性作用的知识点先修后继关系的影响。另外,图卷积网络虽然具有强大的高阶协同信号挖掘能力,能够捕获异构实体之间的关联关系,但其缺乏序列化建模的能力,则无法捕获教育推荐场景中学习者学习需求的动态变化。不同于以上方法,本文在基于异构信息网络的图卷积中引入了知识点之间先修后继元路径的引导,通过图卷积聚合与传播的方式自然地将先修后继关系嵌入到异构实体的表征中;此外,为了捕获用户学习需求的动态变化特征,本文引入了循环神经网络进行序列化建模,并设计了一种统一的框架实现图卷积和循环神经网络的融合,以同时感知并融合用户的静态和动态的学习需求。

1.2 教育领域推荐技术

1.2.1 学习资源推荐方法

近年来,随着在线教育的发展,学习资源推荐已成为各大在线教育平台的核心任务之一。北京大学研究团队^[2]采用一种改进的基于学生的协同过滤推荐算法,通过构建用户的兴趣画像并探寻兴趣相似度相近的用户群体以提供课程推荐,已在北京大学选课系统中得到验证与应用。宋晓丽等人^[3]提出了一种基于改进自编码器的在线课程推荐模型,该模型中利用LSTM (long short term memory) 长短期记忆网络替换自编码器中的前馈神经网络以获得用户更加准确的兴趣画像。上述方法虽然能有效解决“信息过载”问题,但是直接套用电商或多媒体领域中的推荐流程,注重对用户兴趣画像的精准构建,缺乏考虑教育领域中学习需求支配学习行为的特点。因此,近年来,开始有研究团队尝试对用户学习行为中蕴含的学习需求进行挖掘。Zhu等人^[5]设计了一个图式结构的教学评估网络,利用学生对课程的评分、评论文本、成绩以及人际关系等信息以丰富用户和课程的初始化特征表示,然后再通过随机游走以及贝叶斯概率张量分解实现推荐预测。吴昊等人^[23]采用交叉压缩单元建立课程资源推荐任务与知识图谱嵌入任务中的实体之间的特征交互,通过知识图谱上丰富的语义知识对推荐任务中课程资源的输入特征进行初始化。徐欣等人^[6]通过在构建的课程知识图谱上对课程实体与邻接实体的语义知识进行聚合,用以初始化推荐任务中的候选课程,然后对用户-课程交互数据进行卷积操作,实现课程的个性化推荐。Gong等人^[7]通过异构信息网络和图卷积网络利用特征信息和异构关系信息以实现将丰富的语义联系知识融入实体的表达向量中,最后基于获得的用户嵌入表达与知识点嵌入表达进行矩阵分解实现知识点的推荐预测。Wang等人^[8]对用户事先输入的技能属性特征进行主题建模,然后采用变分自编码器网络完成对技能主题的抽取和迁移,以获得蕴含用户学习需求的用户隐向量,最后与蕴含课程属性特征的课程隐向量进行矩阵分解实现推荐结果预测。

综上所述,现有的针对学习需求建模的方法主要通过将课程类别知识与实体关联知识作为额外的辅助信息(如边信息等),对推荐模型的用户特征或学习资源特征进行初始化,能够有效地丰富用户与学习资源自身的嵌入表达,以提升用户兴趣偏好挖掘的准确性。然而,上述方法仅在模型输入时补充知识辅助信息,缺乏对学习资源之间复杂的关联关系进行建模,无法精准地捕获到用户的静态学习需求。除此之外,上述方法在建模过程中缺乏考虑用户学习需求的动态变化特征。因此,本文提出了一种基于静态与动态学习需求感知的知识点推荐方法,从更细粒度的知识点交互的角度建模用户的学习需求以提供精准的推荐。其中,静态学习需求建模模块提出一种基于先修后继元路径引导的图卷积方法,并结合其他多种用户交互元路径实现对推荐过程中静态学习需求的显式建模;动态学习需求建模模块显式编码用户在不同时刻的知识水平,并采用GRU (gated recurrent unit) 门控循环单元网络提取用户的动态学习需求;最终通过一个统一的框架将两种学习需求进行融合,以提供更加精准且合理的个性化知识点推荐。为了与现有的教育领域推荐方法进行更好的区分,本文从待推荐的学习资源类型以及所采用的模型结构两方面对前述方法与本文提出的方法的差异进行总结,总结结果如表1所示。由表1可知,现有的方法仅基于单一类型的模型结构对粗粒度的课程交互进行建模,忽略了单一模型结构自身的建模能力限制,且建模粒度不够精细。而本文提出基于静态与动态学习需求感知的知识点推荐方法是首次在知识点推荐任务中同时引入图神经网络与循环神经网络的方法,同时捕获并融合用户的静态与动态学习需求,能够弥补单一结构模型建模能力有限的缺陷,进而提升个性化知识点推荐的性能。

1.2.2 与知识追踪任务的对比

近年来,随着智慧教育的发展,各类面向用户学习行为的数据挖掘任务开始获得学术界的广泛关注,如知识追

踪与教育领域推荐等。本节将从知识追踪与教育领域推荐两个任务的定义出发进行对比，并对两个任务的输入与输出的差异性进行介绍，最后对两种任务的联系进行讨论。

表1 教育领域推荐方法的对比

方法名称	待推荐的学习资源类型	使用结构		
		图神经网络	循环神经网络	自编码器等
沈苗等人 ^[2]	课程	—	—	√
宋晓丽等人 ^[3]	课程	—	√	—
Zhu等人 ^[5]	课程	√	—	—
吴昊等人 ^[23]	课程	√	—	—
徐欣等人 ^[6]	课程	√	—	—
Gong等人 ^[7]	知识点	√	—	—
Wang等人 ^[8]	课程	—	—	√
本文方法	知识点	√	√	—

(1) 知识追踪^[24]，是一种认知诊断方法，主要通过分析学生过去的答题表现/成绩，评估学生对习题中蕴含的各个知识点的实际掌握情况，并根据评估的知识点掌握情况预测该学生在之后的解题表现，即成绩预测。在该任务中，模型的输入为学生-习题的答题表现/成绩，模型的输出为对后续特定习题的成绩预测，即给定一道习题，预测该学生在该特定习题上的成绩表现，本质上为习题明确的成绩预测任务。

(2) 教育领域推荐，旨在从学生对课程、视频以及知识点的异构交互数据中挖掘该学生的学习需求，然后基于捕获的学习需求对海量的学习资源进行信息过滤，最终为该学生推荐能够满足其个人学习需求的学习资源集合。在该任务中，模型的输入为学生与课程、视频以及知识点的学习交互数据，模型的输出为后续学生可能会学习的一系列学习资源，即在学生不明确后续要学习的学习资源时，为该学生提供个性化的引导，本质上为学习方向不明确的学习资源过滤任务。

(3) 知识追踪与知识点推荐的联系：知识追踪和教育领域推荐两个任务均需要面向学生与知识点的联系进行建模，虽有不同，但这两种任务都是围绕学生的个性化画像进行挖掘的研究。Wang等人^[25]提出两个任务的结合与相互增强将会是未来发展的一个有趣的研究方向。目前，已存在一部分研究尝试根据两种任务的互补性进行多任务融合，例如，Jiang等人^[25]将知识追踪模型引入推荐场景中，基于学生的历史课程选修记录以及历史课程成绩进行建模，将课程推荐任务与知识追踪任务进行融合，实现根据学生预测达到的成绩与学生输入的目标课程实现后续的课程推荐；Zhao等人^[26]则将两个任务进行串联融合，先利用知识追踪模型评估学生的实时知识状态，再使用协同过滤推荐的方法为学生提供学习资源推荐。

综上所述，知识追踪与知识点推荐两项任务在定义、模型输入以及模型输出上均存在较大的差异，但其均面向知识点与用户个性化画像进行研究，可相互补充与强化。本文的研究工作主要是针对教育领域中知识点推荐任务的创新。

2 研究动机

有研究表明，用户的行为是意图驱动的，而在教育场景中，用户的学习行为受用户的学习需求以及兴趣偏好两种意图共同作用驱动^[1,27]。不同于其他应用领域（如电影推荐、商品推荐等）中以用户兴趣偏好为主导，教育领域中个性化推荐的用户是学习者，学习者的学习需求对其学习行为起主导驱动作用。由于教育场景中的“学习需求主导”特征，若仅考虑用户的兴趣偏好进行学习资源推荐，则可能偏离用户的学习目标，最终导致“学习失败”现象。**图1**展示了一个用户按时间顺序排序的知识点学习行为序列，共有3个时间阶段。如**图1**中蓝色框图的知识点所示，该用户首先在第1阶段学习了深度学习相关的基础知识，然后在第2阶段完成对主流的深度学习推荐模型的学习，在第3阶段进一步学习了关于大规模深度学习推荐模型训练与部署的相关知识，可见该用户以完成推荐系统实战

部署为学习目标。同时, 图 1 中的红色框图体现了用户对分布式存储与计算等知识的兴趣偏好。若后续仅考虑用户对分布式存储与计算等知识的兴趣偏好, 进而在下一学习阶段为用户推荐分布式计算的进阶知识, 则会偏离用户的学习目标, 无法满足用户的学习需求, 导致用户花费了大量时间学习不满足自己学习需求与目标的知识, 最终产生“学习失败”现象。因此, 在教育领域推荐场景中, 个性化学习资源推荐方法需要显式地感知与挖掘用户学习行为中蕴含的学习需求, 剔除用户兴趣偏好的影响, 为用户推荐满足其个人学习需求的学习资源推荐, 从而提升用户的学习效率以及学习效果^[28]。

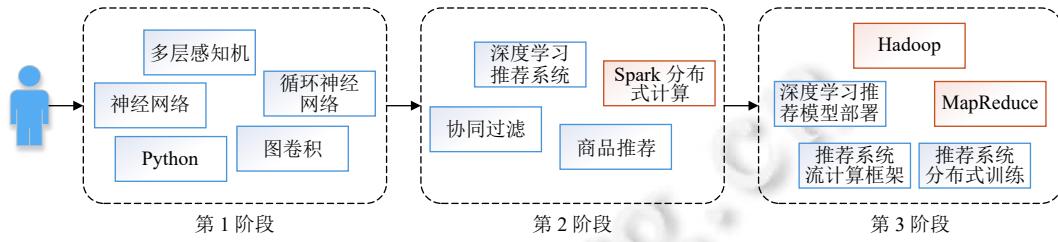


图 1 用户学习行为示例

经分析认为, 用户的学习需求主要包含静态的学习需求和动态的学习需求。静态的学习需求指的是用户所有的历史学习行为数据中蕴含的长期学习需求。动态的学习需求指的是用户在每一个时间段内的学习行为中体现出来的短期学习需求。对于静态的学习需求, 其特点主要是持续时间长且较为稳定, 需要受到知识点之间先修后继关系的约束。为了显式地对其进行建模, 本文考虑构建基于知识点先修后继关系的元路径, 引导图卷积网络对用户所有的历史学习行为进行建模, 以捕获用户学习行为中潜在的静态学习需求。对于动态的学习需求, 其特点主要是持续时间短且具有动态特性, 会随着用户在不同时间阶段内知识水平的提升而动态变化。为了显式地对其进行建模, 本文考虑对用户不同时间阶段内的知识水平进行显式编码, 然后采用循环神经网络对用户按时间排序的知识水平序列进行序列化建模, 以捕获用户在下一学习时刻的动态学习需求。最后, 为了更加综合地考虑学习者的学习需求特征, 本文考虑将挖掘得到的用户的静态学习需求与动态学习需求进行融合, 以获得更加全面且精准的学习需求, 为用户提供更加个性化的学习资源推荐。

3 基于静态与动态学习需求感知的知识点推荐方法

3.1 提出的方法

本节将对提出的基于静态与动态学习需求感知的知识点推荐方法进行详细介绍, 其框架如图 2 所示, 主要包括静态学习需求建模模块、动态学习需求建模模块以及知识遗忘矩阵分解模块。首先, 由于现有的教育领域推荐方法仅将知识的类别或知识点之间的关联关系作为边信息, 以此初始化模型的输入特征, 此方式缺乏在建模过程中挖掘知识点先修后继关系约束下的用户学习需求。因此, 静态学习需求建模模块基于异构知识网络进行特征初始化, 然后采用知识元路径, 特别是先修后继知识元路径, 引导注意力图卷积网络计算得到用户静态学习需求嵌入表达和知识点嵌入表达。其次, 由于现有的方法仅基于用户的所有历史学习交互进行全局隐式的学习需求挖掘, 缺乏考虑用户知识水平在学习过程中的动态变化对用户后续学习需求的影响。因此, 动态学习需求建模模块以课程为粒度, 聚合课程中包含的知识点嵌入表达, 编码用户在完成每个课程学习后的知识水平, 然后采用循环神经网络挖掘知识水平动态变化中蕴含的动态学习需求, 并将获得的用户动态学习需求嵌入表达与静态学习需求嵌入表达进行拼接融合, 获得综合的用户学习需求嵌入表达; 最后, 知识遗忘矩阵分解模块基于用户的历史学习行为, 采用一种扩展的矩阵分解模型对推荐结果进行预测。

在知识点推荐场景中, 存在大量的用户、知识点以及用户的历史知识点交互学习行为。本文用 U 表示用户集合, K 表示知识点集合, 其中 $|U|$ 和 $|K|$ 分别表示用户总数和知识点总数。由于每个课程都涵盖了一系列的知识点, 用户通过对课程进行学习以实现对知识点的学习, 则本文用每个课程中包含的知识点集合来表示每个课程, 将用

户 $u \in U$ 按照时间先后顺序排序的完整知识点集合学习序列表示为 $C_u = \{c_u^1, \dots, c_u^t, \dots, c_u^m\}$, 其中 c_u^t 表示用户 u 所有知识点集合学习序列中第 t 个知识点集合, 即第 t 门课程, m 表示该用户的知识点集合学习序列长度为 m . 同时, 在线学习平台上除了用户、课程和知识点外还存在着许多种其他类型的实体(如视频和教师等)以及不同实体对之间的多种交互关系, 不同类型实体对之间的关联关系我们称之为异构关系. 这些实体之间的异构关系提供了丰富的语义信息, 能够有效提高实体表达学习的准确性^[7], 则本文将由上述实体结点以及异构关系连边构成的异构知识网络记为 G . 个性化知识点推荐任务在于对异构知识网络 G 和知识点集合学习序列 C_u 进行建模, 挖掘用户的潜在学习需求, 预测在下一时刻满足目标用户 u 学习需求的知识点集合 c_u^{m+1} .

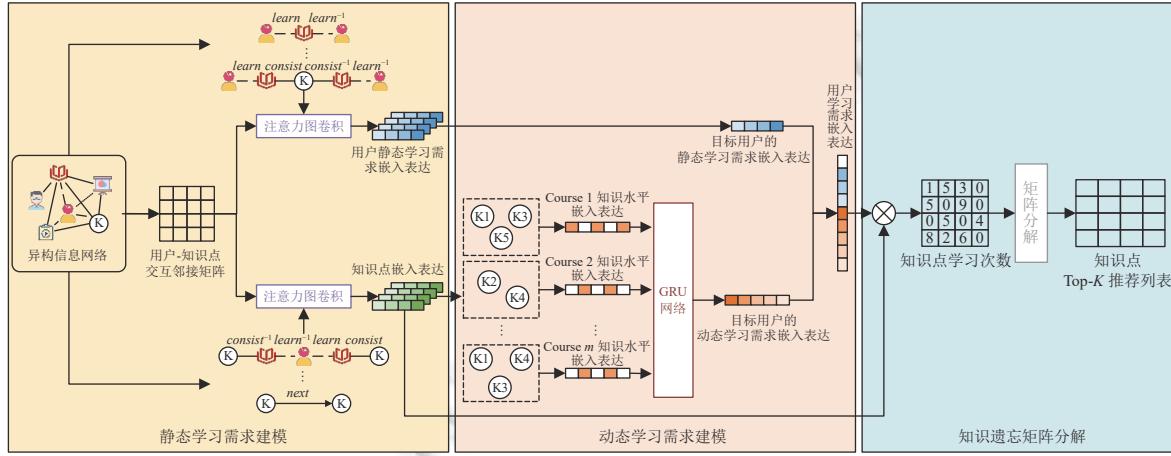


图2 框架原理图

3.1.1 静态学习需求建模

不同于其他领域的推荐场景, 在教育领域中, 用户的学习行为中同时蕴含了用户的学习需求以及兴趣偏好, 并且, 相较于兴趣偏好, 用户的学习需求对用户的学习行为起主导支配作用. 而知识点的先修后继关系的引入, 能够在建模过程中引导用户消除兴趣偏好意图等其他干扰因素的影响, 有助于学习需求的精炼. 因此, 本文设计了静态学习需求建模模块, 创新性地在知识点推荐任务中引入知识点的先修后继关系引导, 旨在利用异构知识网络 G 中的多种异构关系(如知识点的先修后继、用户-课程、用户-知识点、课程-知识点、教师-课程等), 对其中蕴含的用户潜在的学习需求实现显式地挖掘. 如后文图3所示, 静态学习需求建模模块主要包括特征初始化以及元路径引导的注意力图卷积两个步骤.

3.1.1.1 特征初始化

为了将异构知识网络 G 中蕴含的多种实体间的异构关联关系转化为模型的输入数据, 本文对用户以及知识点进行特征初始化, 特征初始化模块包括内容特征初始化以及知识元路径特征初始化.

(1) 内容特征初始化. 内容特征初始化主要包括用户内容特征初始化以及知识点内容特征初始化两个方面. 一方面, 考虑到用户在学习过程中以课程作为学习单元, 因此本文将用户与课程的交互行为视作用户内容特征, 用户的内容特征 f_{user} 初始化如公式(1)所示:

$$f_{user} = D^{-1} \cdot A_{uc} \quad (1)$$

其中, A_{uc} 代表用户-课程的交互邻接矩阵, 若用户存在与一门课程的学习交互行为, 则该矩阵对应用户-课程的元素值赋值为 1, 否则为 0. D 表示 A_{uc} 的度矩阵, 度矩阵中除了对角线外其他元素都为 0, 其对角线上的元素 D_{ii} 表示与用户 $i \in U$ 相连的课程数. 度矩阵 D 的计算过程如公式(2)所示:

$$D = diag(A_{uc}) \quad (2)$$

其中, $diag(\cdot)$ 表示对角化操作.

另一方面, 考虑到知识点的名称包含了丰富的语义信息(如“线性表”和“链表”等相近的知识点名称在高维空间具有距离较近的语义关系), 因此本文采用 *Word2Vec*^[29]生成知识点名称的词嵌入作为知识点的内容特征, 知识点的内容特征 $f_{concept}$ 初始化如公式(3)所示:

$$f_{concept} = \text{Word2Vec}(concept_name) \quad (3)$$

其中, $concept_name$ 表示知识点的名称, $\text{Word2Vec}(\cdot)$ 表示采用 *Word2Vec* 词向量化方式将知识点的名称转换为向量表示, 即可获得知识点的内容特征向量。

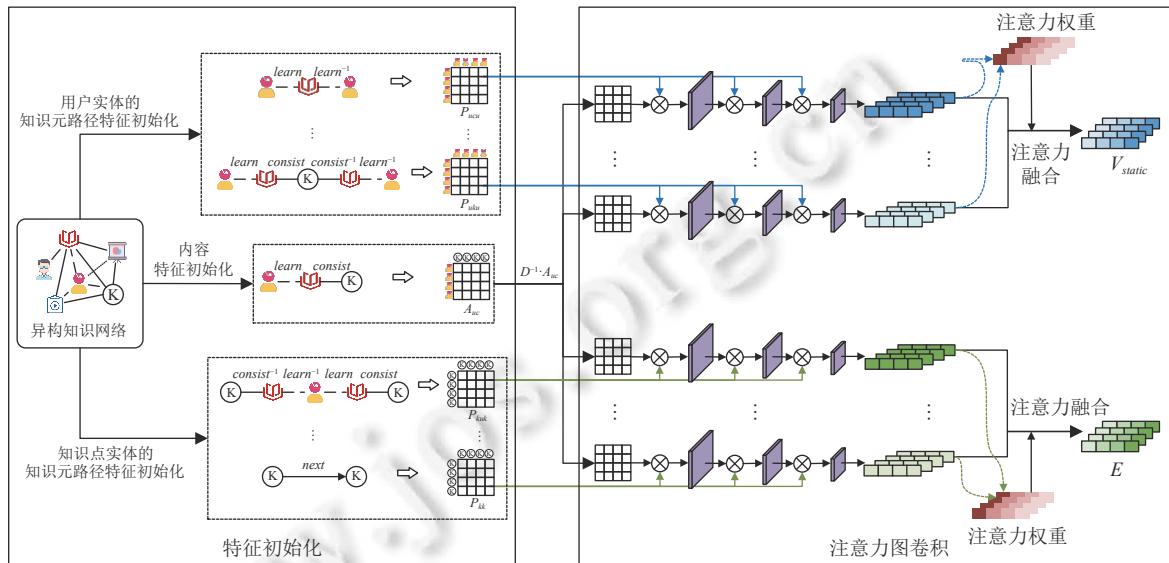


图 3 静态学习需求建模

(2) 知识元路径特征初始化。由于不同类型实体之间存在多种异构关联关系, 为了分析不同类型的异构关系以挖掘用户的学习需求并描述知识点, 本文基于异构知识网络 G 中的不同交互关系进行知识元路径特征初始化。基于知识元路径进行推荐建模有助于定向地捕获各类型异构关联关系中的知识约束, 特别是知识点的先修后继关联关系, 从而更加精准地提取用户的学习需求。考虑到异构知识网络的复杂性, 本文根据两个实体是否是同种类型将知识元路径划分为交互知识元路径以及先修后继知识元路径。其中, 交互知识元路径表征不同类型实体之间的关联关系, 先修后继知识元路径表征两个知识点实体之间的先后学习依赖关系。

对于交互知识元路径, 由于文献[7]中通过充分的元路径选择实验证明了 $K \xrightarrow{\text{grasp}^{-1}} U \xrightarrow{\text{grasp}} K$ (一个用户掌握了两个不同的知识点)、 $U \xrightarrow{\text{learn}} C \xrightarrow{\text{learn}^{-1}} U$ (两个用户学习了同一门课程)、 $U \xrightarrow{\text{grasp}} K \xrightarrow{\text{grasp}^{-1}} U$ (两个用户掌握了同一个知识点)、 $U \xrightarrow{\text{learn}} C \xrightarrow{\text{teach}^{-1}} T \xrightarrow{\text{teach}} C \xrightarrow{\text{learn}^{-1}} U$ (两个用户学习了由同一名教师教授的两门不同的课程)、 $U \xrightarrow{\text{watch}} V \xrightarrow{\text{watch}^{-1}} U$ (两个用户观看了同一个学习视频) 这 5 种元路径对推荐的贡献最大。因此, 本文直接选取这 5 种元路径进行交互知识元路径的初始化。以元路径 $U \xrightarrow{\text{grasp}} K \xrightarrow{\text{grasp}^{-1}} U$ 为例, 本文将该元路径简记为 uku , 则元路径 uku 对应的元路径邻接矩阵 A_{uku} 构建过程如公式(4)所示:

$$A_{uku} = A_{uk} A_{uk}^T \quad (4)$$

其中, A_{uk} 表示用户-知识点交互的邻接矩阵, 若用户 u_i 存在与知识点 k_l 的学习交互记录, 则对应元素 $a_{u_i k_l} \in A_{uk}$ 的值为 1, 否则为 0; A_{uk}^T 表示邻接矩阵 A_{uk} 的转置矩阵。基于计算得到的元路径邻接矩阵 A_{uku} , 则 uku 带有自连接特征的元路径邻接矩阵 \tilde{A}_{uku} 可通过公式(5)获得:

$$\tilde{A}_{uku} = A_{uku} + I \quad (5)$$

其中, I 表示单位矩阵, 即矩阵 I 是一个方阵且该矩阵中所有的对角线元素均为 1, 其余元素均为 0。基于公式(5)

计算获得的带有自连接特征的元路径邻接矩阵 \tilde{A}_{uku} , 可通过公式(6)计算获得 \tilde{A}_{uku} 的度矩阵 D_{uku} :

$$D_{uku} = \text{diag}(\tilde{A}_{uku} \cdot 1) \quad (6)$$

其中, $\text{diag}(\cdot)$ 表示矩阵对角化操作, 1 表示全 1 向量, 即度矩阵 D_{uku} 为一个对角方阵, 该矩阵中所有对角线上的元素表示与该元素对应的用户节点相关联的边的数量. 基于获得的带有自连接特征的元路径邻接矩阵 \tilde{A}_{uku} 及其度矩阵 D_{uku} , 可通过公式(7)计算获得 uku 的元路径特征矩阵 P_{uku} , 该元路径特征矩阵后续可用于引导图卷积的信息聚合过程.

$$P_{uku} = D_{uku}^{-\frac{1}{2}} \tilde{A}_{uku} D_{uku}^{-\frac{1}{2}} \quad (7)$$

类似地, 其他类型的交互知识元路径的特征矩阵计算同上.

对于先修后继知识元路径, 由于用户与知识点的学习交互中蕴含了用户的学习需求, 这些学习需求受到知识点之间复杂关联关系的约束与限制. 因此, 为了显式地挖掘用户的学习需求, 本文基于知识点之间的先修后继关系构造先修后继知识元路径, 以引导模型从用户学习行为中提取出用户的学习需求. 在此, 本文考虑一阶的先修后继知识元路径 $K \xrightarrow{\text{next}} K$, 简记为 kk , 表示在用户学习过程中两个知识点之间的一阶先修后继关系, 在该元路径中两个知识点的先修后继关系是定向不可逆的. 本文的研究贡献之一为先修后继知识元路径的引入能否有效提升知识点推荐的效果, 故仅在模型中引入对一阶的先修后继关系进行建模, 高阶的先修后继关系以及知识点之间的其他关联关系(如包含关系等)的探索作为本文后续的研究方向. 一阶先修后继知识元路径 kk 带有自连接特征的元路径邻接矩阵 \tilde{A}_{kk} 构造过程如公式(8)所示:

$$\tilde{A}_{kk} = A_{kk} + I \quad (8)$$

其中, A_{kk} 表示知识点-知识点的一阶先修后继邻接方阵, 该矩阵的行和列均表示知识点, 若知识点 k_1 为知识点 k_2 的先修知识点(知识点 k_2 为知识点 k_1 的后继知识点), 则对应元素 $a_{k_1 k_2} \in A_{kk}$ 的值为 1, 否则为 0. 基于公式(8)获得的带有自连接特征的元路径邻接矩阵 \tilde{A}_{kk} , 则该矩阵对应的度矩阵 D_{kk} 计算如下:

$$D_{kk} = \text{diag}(\tilde{A}_{kk} \cdot 1) \quad (9)$$

其中, $\text{diag}(\cdot)$ 表示矩阵对角化操作, 1 表示全 1 向量, 即度矩阵 D_{kk} 为一个对角方阵, 该矩阵中所有对角线上的元素表示与该元素对应的知识点节点相关联的边的数量. 根据带有自连接特征的元路径邻接矩阵 \tilde{A}_{kk} 及其度矩阵 D_{kk} , 可通过公式(10)计算获得一阶先修后继知识元路径 kk 的元路径特征矩阵 P_{kk} , 该元路径特征矩阵后续可用于引导图卷积的信息聚合过程.

$$P_{kk} = D_{kk}^{-\frac{1}{2}} \tilde{A}_{kk} D_{kk}^{-\frac{1}{2}} \quad (10)$$

3.1.1.2 元路径引导的注意力图卷积

为了对异构知识网络 G 中蕴含的用户学习需求进行显式地挖掘, 本文借鉴并采用 Gong 等人^[7]提出的元路径引导的注意力图卷积框架, 在该框架的基础上补充引入本文提出的知识点的先修后继知识元路径, 并融合其他多种用户交互关系的元路径, 然后基于多种知识元路径的初始化特征矩阵引导网络关注对用户静态学习需求的建模. 元路径引导的注意力图卷积模块包括元路径引导图卷积以及注意力异构关系融合两个部分.

(1) 元路径引导图卷积. 由于用户的学习行为数据中包含多种类型实体以及多种实体之间复杂的异构关联关系, 这些异构关系提供了丰富的语义信息, 有助于提升推荐模型的效果^[7]. 不同于现有的仅考虑用户行为中不同类型实体之间交互元路径的相关工作, 本文在已有元路径的基础上创新性地提出了知识点的先修后继知识元路径, 通过知识点实体之间的先修后继关联关系约束剔除用户兴趣偏好意图的影响, 提取用户历史行为中潜在的静态学习需求. 具体地, 元路径引导图卷积首先基于第 3.1.1.1 节中获得的用户以及知识点的初始内容特征嵌入表达 f_{user} 以及 $f_{concept}$ 作为模型输入, 然后利用第 3.1.1.1 节中构造的交互知识元路径特征矩阵 (P_{ucu} 、 P_{uku} 、 P_{uvu} 、 P_{uctu} 以及 P_{kuk}) 以及先修后继知识元路径特征矩阵 P_{kk} 替换普通图卷积中的用户-物品邻接矩阵分别进行信息传播, 以挖掘不同实体之间的异构关联关系. 由于不同元路径引导图卷积的建模过程都是一致的, 因此, 本节以知识点先修后继知识元路径 P_{kk} 为例, 对元路径引导图卷积的计算过程进行介绍. 基于先修后继知识元路径 P_{kk} 引导多层图卷积的信息传播规则如公式(11)所示:

$$h_{kk}^{l+1} = \sigma(P_{kk} h_{kk}^l W^l) \quad (11)$$

其中, h_{kk}^{l+1} 表示元路径特征 P_{kk} 引导下经过 $l+1$ 层图卷积后获得的一个实体(用户或知识点)的最新嵌入表达, $\sigma(\cdot)$ 表示 ReLU 非线性激活操作, l 为图卷积网络层数的标志. W^l 表示在层 l 时所有实体共享的可训练权重参数, 权重共享有利于更好地进行模型正则化, 且能够客观地减少模型的参数规模. 特别地, h^0 表示在特征初始化模块中用户或知识点的内容特征初始化嵌入表达 f_{user} 及 $f_{concept}$. 同理, 其他元路径引导下的实体嵌入表达可通过式(11)所述的多层图卷积信息传播获得.

(2) 注意力异构关系融合. 考虑到不同元路径引导图卷积获得的实体嵌入表达蕴含的知识信息不同, 同时不同元路径的重要性程度不同. 因此, 注意力异构关系融合对不同元路径引导获得的实体嵌入表达采用注意力机制实现知识的自动加权融合, 以获得最终的用户静态学习需求嵌入表达与知识点嵌入表达. 由于针对不同实体的注意力异构关系融合过程都是一样的, 因此, 对于用户, 本文将以用户实体为起点与终点的元路径构成的集合记为 $MP_U = \{uku, ucu, uctcu, uvu\}$, 于是对于用户实体的注意力异构关系融合过程如公式(12)所示.

$$v_{static} = \sum_{mp \in MP_U} \alpha_u^{mp} e_u^{mp} \quad (12)$$

其中, v_{static} 表示融合了 MP_U 集合中所有元路径引导下用户实体嵌入表达后获得的最终的用户实体嵌入表达, 即用户的静态学习需求嵌入表达; mp 表示 MP_U 集合中任意的一条元路径; $e_u^{mp} = h_{mp}^{l+1}$ 表示在元路径 mp 引导下经过图卷积获得的用户实体嵌入表达; α_u^{mp} 表示元路径 mp 对应的注意力权重, 注意力权重的计算方式如公式(13)所示:

$$\alpha_u^{mp} = \frac{\exp(\rho(W_u^a e_u^{mp}))}{\sum_{p \in MP_U} \exp(\rho(W_u^a e_u^p))} \quad (13)$$

其中, W_u^a 表示一个可训练的权重参数, $\rho(\cdot)$ 表示非线性激活函数. 同理, 对于知识点, 本文将以知识点实体为起点与终点的元路径构成的集合记为 $MP_K = \{kk, kuk\}$, 则对于知识点实体的注意力异构关系融合过程如公式(14)所示:

$$v_k = \sum_{mp \in MP_K} \alpha_k^{mp} e_k^{mp} \quad (14)$$

其中, $v_k \in E$ 表示融合了 MP_K 集合中所有元路径引导下知识点实体嵌入表达后获得的最终的知识点实体嵌入表达, E 表示所有知识点的实体嵌入表达集合; mp 表示 MP_K 集合中任意的一条元路径; $e_k^{mp} = h_{mp}^{l+1}$ 表示在元路径 mp 引导下经过图卷积获得的知识点实体嵌入表达; α_k^{mp} 表示元路径 mp 对应的注意力权重, 注意力权重的计算方式如公式(15)所示:

$$\alpha_k^{mp} = \frac{\exp(\rho(W_k^a e_k^{mp}))}{\sum_{p \in MP_K} \exp(\rho(W_k^a e_k^p))} \quad (15)$$

其中, W_k^a 表示一个可训练的权重参数, $\rho(\cdot)$ 表示非线性激活函数.

3.1.2 动态学习需求建模

在学习过程中, 用户的学习需求会随着用户自身知识水平的提升而动态变化, 基于智慧教育中提倡的因材施教原则, 个性化的教育推荐需要建模用户的动态学习需求, 然后根据用户的动态学习需求为其推荐合适的学习资源^[30]. 因此, 本文设计了动态学习需求建模模块, 旨在利用静态学习需求建模过程中获得的知识点嵌入表达, 对用户在学习过程中的知识水平变化进行追踪, 以挖掘下一时刻用户的动态学习需求. 如后文图4所示, 动态学习需求建模主要包括序列化知识水平编码和动态学习需求挖掘两个步骤.

3.1.2.1 序列化知识水平编码

为了表征用户的知识水平, 本文以用户学习的课程为编码单元, 划分每个课程包含的知识点集合, 然后基于静态学习建模模块获得的知识点嵌入表达, 对知识点集合中包含的知识点对应的嵌入表达进行累加聚合^[31,32], 以获得用户在学习完对应课程(知识点集合)后提升的知识水平, 如公式(16)所示.

$$v_{\text{knowledge}}^t = \sum_{i=1}^{|c_u^t|} e_{u,t}^i \quad (16)$$

其中, $v_{\text{knowledge}}^t$ 表示用户 u 在学习完课程 c_u^t 后提升的知识水平, $|c_u^t|$ 表示课程 c_u^t 中的知识点数量, $e_{u,t}^i \in E$ 表示由静态学习需求建模模块计算获得的课程 c_u^t 中第 i 个知识点的嵌入表达。在此, 本文仅使用简单的累加操作来编码用户的知识水平, 把考虑用户知识掌握程度的聚合方式作为本文未来的研究方向。

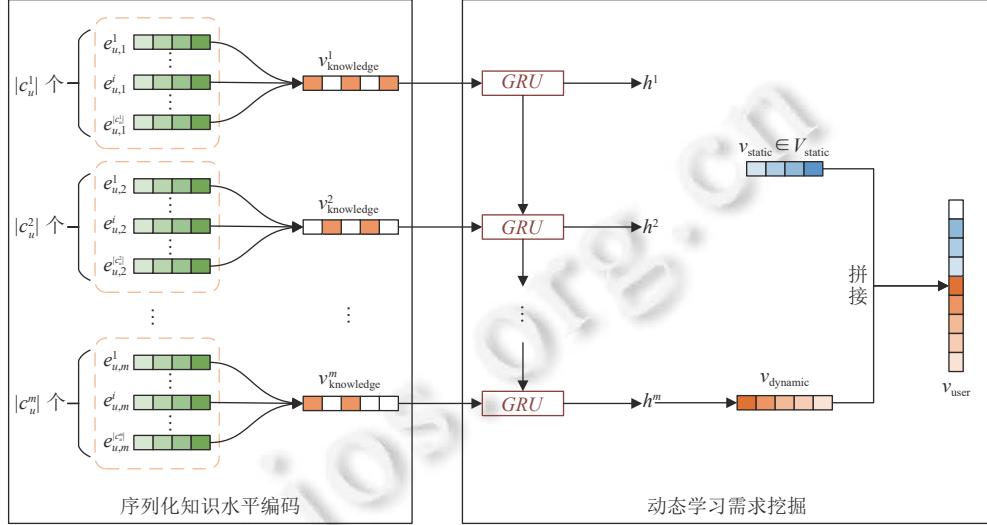


图 4 动态学习需求建模

3.1.2.2 动态学习需求挖掘

考虑到用户的学习需求会随着用户知识水平的变化而动态变化, 为了挖掘用户学习需求的动态变化, 本文采用具有动态序列化建模能力的循环神经网络 RNN (recurrent neural network) 模型^[33]实现对知识水平的动态编码。在动态学习需求挖掘中, 首先将用户的知识水平嵌入表达按照课程学习的先后顺序进行排序, 获得用户 u 的知识水平变化序列 $V_{\text{knowledge}} = \{v_{\text{knowledge}}^1, \dots, v_{\text{knowledge}}^t, \dots, v_{\text{knowledge}}^m\}$, m 表示用户 u 学习的课程数量。其次, 本文采用 RNN 模型的变体模型门控循环单元网络 GRU^[34]对知识点集合学习序列 $V_{\text{knowledge}}$ 进行序列化动态编码, 其编码过程如公式 (17) 所示:

$$h^t = \text{GRU}(v_{\text{knowledge}}^t, h^{t-1}) \quad (17)$$

其中, h^t 表示 t 时刻 GRU 模型的隐藏状态输出, $\text{GRU}(\cdot)$ 表示进行 GRU 序列化建模操作, h^{t-1} 表示上一时刻 GRU 模型的隐藏状态输出。然后, 本文只使用最后时刻 GRU 模型输出的隐藏状态表征用户的动态学习需求, 如公式 (18) 所示:

$$v_{\text{dynamic}} = h^m \quad (18)$$

其中, v_{dynamic} 为用户的动态学习需求嵌入表达, m 为目标用户的知识点集合学习序列长度, 即该用户学习的课程数量。由于在 GRU 进行序列化动态建模的过程中仅能感知到用户个体自身的学习需求变化, 无法融合不同用户个体之间的协同信号, 而静态学习需求感知模块中的基于元路径引导的图卷积建模虽然可以融合不同用户个体之间的协同信号, 却只能捕获到全局的静态学习需求, 忽略了用户学习需求的动态性变化。因此, 为了获得更全面且精准的用户学习需求, 本文将静态学习需求建模模块获得的用户静态学习需求嵌入表达 v_{static} 与动态学习需求建模模块获得的动态学习需求嵌入表达进行拼接, 以获得表征用户最终学习需求的嵌入表达向量, 计算过程如公式 (19) 所示:

$$v_{\text{user}} = \text{concat}(v_{\text{static}}, v_{\text{dynamic}}) \quad (19)$$

其中, v_{user} 为最终的用户学习需求嵌入表达, $concat(i, j)$ 表示对向量 i 和向量 j 进行拼接操作.

3.1.3 知识遗忘矩阵分解与模型训练

基于对用户-知识点的学习行为数据分析, 本文发现用户在学习过程中对已学习过的知识会存在遗忘行为. 为了防止重要知识的遗忘, 他们会重复地学习已学过的知识点^[30]. 因此, 为了显式地建模这种行为特征, 本文借鉴并采用了一种基于用户历史行为的扩展的矩阵分解方法^[7,11], 该方法基于用户对知识点的学习次数构造评分矩阵, 同时基于用户历史交互行为获得的用户学习需求嵌入表达与知识点嵌入表达补充到矩阵分解计算中, 有助于缓解冷启动与数据稀疏性问题的影响. 基于静态学习需求建模模块和动态学习需求建模模块获得的知识点 k 的嵌入表达与用户 u 的学习需求嵌入表达, 本文进一步将其传递到扩展的矩阵分解运算中, 如公式(20)所示:

$$\widehat{r}_{u,k} = x_u^T y_k + \beta_u \cdot v_{user}^T W^k + \beta_k \cdot W^{uT} e^k \quad (20)$$

其中, $\widehat{r}_{u,k}$ 为预测次数, $x_u \in \mathbb{R}^{D \times |U|}$ 表示用户的潜在因子, $y_k \in \mathbb{R}^{D \times |K|}$ 表示知识点的潜在因子, D 是潜在因子的数量. v_{user} 是动态学习需求建模模块中获得的用户最终的学习需求嵌入表达, $e^k \in E$ 是静态学习需求建模模块中获得的知识点嵌入表达, W^u 和 W^k 是可训练权重以分别将 v_{user} 和 e^k 映射到相同的嵌入空间中, β_u 和 β_k 是调整参数. 为了综合考虑用户的知识遗忘行为与准确的推荐结果预测, 所以该矩阵分解方法的目标函数定义如公式(21)所示:

$$\min_{U,K} \frac{1}{|U| \times |K|} \sum_{u=1}^{|U|} \sum_{k=1}^{|K|} (r_{u,k} - \widehat{r}_{u,k})^2 + \lambda (\|x_u\|_2 + \|y_k\|_2 + \|t^u\|_2 + \|t^k\|_2) \quad (21)$$

其中, $r_{u,k}$ 为用户对知识点的真实学习次数, $\lambda (\|x_u\|_2 + \|y_k\|_2 + \|t^u\|_2 + \|t^k\|_2)$ 表示进行正则化处理, λ 是正则化参数. 然后, 本文采用随机梯度下降算法实现对目标函数的优化训练.

4 实验

本文在真实数据集上执行 3 个实验, 以验证本文所提出的模型的有效性与先进性, 实验如下.

- (1) 对比实验: 与具有代表性的推荐模型对比以验证我们提出的模型的有效性与先进性.
- (2) 消融实验: 对我们模型中的技术创新点进行控制实验以评估各个技术创新点的效果.
- (3) 参数实验: 对影响模型性能的重要参数进行控制实验分析以评估不同参数的影响.

4.1 数据集

本文采用 2020 年文献 [35] 中公开的一个服务于 MOOC 相关研究的开源大规模数据集 MOOCCube, 该数据集中的学习资源数据与学生行为数据均来自于学堂在线 MOOC 平台的真实使用环境. 特别地, 该数据集以知识点为核心, 将学生行为和学习资源内容通过与知识点建立联系, 构成不同实体之间的相互关联, 旨在为 AI 技术在智慧教育中的应用研究提供数据支持. 由于本文的动态学习需求建模模块需要作用于用户的课程学习序列, 故本文将 MOOCCube 数据集中课程学习数量少于 5 门的用户记录剔除. 除此之外, 本文仅在学科类别为计算机科学与技术和管理科学与技术两个数据子集上进行实验, 最终两个数据集分别标记为 MOOCCube-comp 和 MOOCCube-mana. MOOCCube-comp 和 MOOCCube-mana 两个数据集的实体统计结果与关系统计结果分别如表 2 与表 3 所示. 本文首先将所有用户最后一次视频学习的知识点集合划分为测试集, 作为模型的预测目标, 即用户在下一时刻的可能会学习的知识点集合; 其次, 按时间顺序倒数第 2 次视频学习的知识点集合作为验证集; 最后将剩余的所有知识点学习数据作为训练集. 在训练过程中, 对于验证集中的每个正面实例, 本文随机生成一个负面实例以补充到数据集中, 以便在模型训练时考虑用户的负反馈影响. 在测试过程中, 本文将测试集中每个用户学习的知识点集合与随机采样生成的负面实例进行配对, 每个用户凑齐 100 个知识点预测目标, 以评估模型推荐的性能.

表 2 MOOCCube 数据集的实体统计信息

数据集	用户	课程	视频	教师	知识点
MOOCCube-comp	8359	86	5084	189	4641
MOOCCube-mana	7118	193	7863	409	6648

表 3 MOOCCube 数据集的交互关系统计信息

数据集	用户-课程	课程-视频	教师-课程	视频-知识点	知识点先修后继
MOOCCube-comp	55 366	5 806	240	49 974	1 912
MOOCCube-mana	30 116	9 346	726	76 430	432

4.2 评估指标

为了对本文提出的推荐方法进行客观且统一的推荐效果实验评估, 本文采用在推荐系统中被广泛使用的离线指标来评估所有的模型方法, 指标包括有命中率 HR (hit ratio)^[36]、归一化折损累积增益 $NDCG$ (normalized discounted cumulative gain)^[37,38]、以及召回率 $Recall$ ^[39]。

(1) 命中率 HR : 若一个用户的推荐结果中存在至少一个用户真正学习过的知识点, 则对于该用户而言, 推荐结果命中。命中率表示推荐结果命中的用户数与用户总数的比率。命中率 HR 计算如公式 (22) 所示:

$$HR = \frac{\sum_{u \in U} I(T_u \cap R_u \neq \emptyset)}{|U|} \quad (22)$$

其中, U 表示用户集合, $|U|$ 表示用户总数。 R_u 表示用户 u 的推荐结果的知识点集合, T_u 表示测试集中用户 u 真实学习的知识点集合。 $I(\cdot)$ 为指示性函数, 当括号中的条件测试为真时取值为 1, 否则为 0。

(2) 归一化折损累积增益 $NDCG$: 是一种基于排名的度量指标, 它考虑了知识点在推荐结果的知识点集合中的顺序。对于用户 u , 根据 top- p 推荐结果计算每个用户对应推荐的知识点集合的 $NDCG$ 值, 其计算如公式 (23) 所示:

$$NDCG_{u,p} = \frac{DCG_p}{IDCG_p} = \frac{\sum_{i=1}^p \frac{rel_i}{\log_2(i+1)}}{\sum_{i=1}^{REL_p} \frac{rel_i}{\log_2(i+1)}} \quad (23)$$

其中, p 表示知识点推荐的集合大小为 p 个知识点, DCG_p 表示 p 个知识点集合推荐折损累积增益, $IDCG_p$ 表示理想情况下的最大 DCG_p 值。 REL_p 表示测试集上用户进行后续知识点学习时真实的知识点学习顺序。 rel_i 表示在 i 这个顺序位置上的相关度, 如果预测的知识点存在于测试集知识点集合中, 则 rel_i 赋值为 1, 否则赋值为 0, 以评估系统推荐的后续知识点集合中正面实例推荐的准确性。最后对所有用户的归一化折损累积增益进行求和平均以获得整个模型的 $NDCG$ 指标评估值。

(3) 召回率 $Recall$: 表示一个用户想要学习的知识点被正确推荐的概率, 定义为推荐结果知识点集合中用户想要学习的知识点数量与用户真实学习的所有知识点总数的比率。对于用户 u , 其召回率 $Recall_u$ 计算如公式 (24) 所示:

$$Recall_u = \frac{N_{tp}}{|T_u|} \quad (24)$$

其中, N_{tp} 表示用户真实学习过的知识点被正确推荐的数量, T_u 表示测试集中用户 u 真实学习的知识点集合, $|T_u|$ 表示测试集中用户 u 真实学习的知识点总数。最后对所有用户的召回率进行求和平均以获得整个模型的 $Recall$ 指标评估值。

基于上述的评估指标, 本文分别选取推荐集合大小为 5 和 10 进行命中率 HR 、归一化折损累积增益 $NDCG$ 以及召回率 $Recall$ 的指标计算, 以评估推荐列表中顺序的相关性以及推荐的准确性。

4.3 对比模型

为了评估本文提出的模型的性能, 本文分别与传统的推荐方法、深度学习推荐方法、以及教育领域推荐方法进行比较。传统的推荐方法包括: 基于物品的协同过滤推荐模型 ItemCF、基于受欢迎程度的统计推荐方法 POP。深度学习推荐方法包括: 多层感知机推荐模型 MLP、轻量级图卷积神经网络推荐模型 LightGCN、无采样高效神经矩阵分解推荐模型 ENMF、基于余弦对比损失的协同过滤推荐模型 SimpleX。教育领域推荐方法包括: 基于注

意的异构图卷积深度知识推荐模型 ACKRec.

(1) 传统的推荐方法

ItemCF: ItemCF 模型^[10]是基于物品相似度进行推荐的经典协同过滤推荐算法。主要通过计算物品共现矩阵中物品列向量的相似度得到物品之间的相似矩阵, 再搜索与用户历史交互行为中物品的相似度最高的物品以提供结果推荐。本文使用自己实现的 ItemCF 代码进行对比实验。

POP: POP 模型^[32]是一种基于统计的方法, 主要通过统计训练集中物品的全局受欢迎程度进行 top- k 推荐, 被广泛地用于推荐效果的比对。本文使用自己实现的 POP 代码进行对比实验。

(2) 深度学习推荐方法

MLP: MLP 模型是被广泛使用的经典深度学习推荐模型, 该模型通过多层感知机的任意函数拟合能力, 建模用户的历史交互行为, 最终为用户提供个性化推荐, 是各类深度学习推荐模型的基础模型。本文使用自己实现的 MLP 代码进行对比实验。

LightGCN: LightGCN 模型^[15]剔除了在推荐场景下图卷积网络中不必要的冗余构件——特征转换与非线性激活, 简化了图卷积推荐模型的结构与计算、并增强了图卷积推荐模型的推荐效果, 是一种主流的轻量级图卷积推荐模型。本文直接使用其官方开源的代码 <https://github.com/gusye1234/LightGCN-PyTorch> 进行对比实验。

ENMF: ENMF 模型^[19]针对负采样的弊端提出了一个高效的矩阵分解模型, 该模型从整个训练数据中学习神经网络推荐模型, 而不需要进行采样, 并设计了 3 种新的优化方法在保持模型推荐效果的同时对时间复杂度进行优化。本文直接使用 RecBole 框架^[40]中开源的代码进行对比实验。

SimpleX: SimpleX 模型^[20]提出了一种新的损失函数 CCL (cosine contrastive loss), 旨在最大化正样本对之间的相似性, 并最小化边距约束下的负样本的相似性。SimpleX 是一种主流的通用的协同过滤推荐模型。本文直接使用 RecBole 框架^[40]中开源的代码进行对比实验。

(3) 教育领域推荐方法

ACKRec: ACKRec^[7]模型使用异构知识元路径引导基于注意力机制的图卷积网络, 以挖掘不同实体交互关系中蕴含的用户的隐式学习需求。本文直接使用其官方开源的代码 <https://github.com/JockWang/ACKRec> 进行对比实验。

对于以上的所有对比模型, 本文依照各个模型所在的原论文中的参数搜索空间, 在两个数据集上进行网格调参, 以确定各个对比模型的最优性能。值得注意的是, 由于 ACKRec 模型已在学堂在线的 MOOC 数据集上与主流的基于异构信息网络的推荐模型进行了相同指标上的对比, 并证明了 ACKRec 模型的优越性。因此, 本文没有将基于异构信息网络的推荐模型列入对比模型列表中, 只需证明本文提出的方法优于 ACKRec 即可说明文本提出的方法优于主流的基于异构信息网络的推荐模型。

4.4 对比实验分析

为了验证本文提出的模型的性能优越性, 本文与现有方法在 MOOCCube-comp 和 MOOCCube-mana 两个真实数据集上进行了性能的对比。本文根据第 4.2 节中推荐集合大小的设定以及评估指标的计算方法进行不同推荐模型推荐结果的指标计算, 在 MOOCCube-comp 和 MOOCCube-mana 两个真实数据集上的实验结果如表 4 所示。

表 4 展示了本文提出的模型与 5 个对比方法在两个数据集上的指标对比结果, 其中, 加粗的结果表示该结果是最优的、下划线表示次优的结果、斜体表示该结果指标排名第 3, 由表 4 可得以下一些结论。

首先, 对于知识点推荐任务, 在两个基准数据集上, 本文提出的基于静态与动态学习需求感知的知识点推荐方法在大多数指标上均优于所有的基线方法, 验证了本文提出的方法的优越性。在剩余的非最优的指标上, 本文的方法也在排名前 3 之中, 体现出不错的竞争力。本文提出的方法的优势主要包括 3 个方面: 第一, 本文首次在知识点推荐任务中引入知识点先修后继的元路径, 通过主流的基于元路径的注意力图卷积网络在信息聚合过程中自然地融合知识点先修后继关系的引导, 以捕获更精准的用户全局的静态学习需求; 第二, 本文以课程为单位聚合课程中包含的知识点嵌入表达来表征用户在不同时刻的知识水平, 再采用循环神经网络建模编码用户在不同时刻的知识

水平,以捕获知识水平变化中蕴含的用户的动态学习需求;第三,本文设计了一个统一的框架实现图卷积网络与循环神经网络的集成与融合,据我们所知,本文是第一个在知识点推荐任务中将两种各有优劣的网络模型进行集成的方法,能够促使两个网络的优缺点实现互补。

表4 两个数据集上的对比实验结果

数据集	对比模型	<i>HR@5</i>	<i>HR@10</i>	<i>Recall@5</i>	<i>Recall@10</i>	<i>NDCG@5</i>	<i>NDCG@10</i>
MOOCCube-comp	ItemCF	0.0069	0.0486	0.0014	0.0049	0.0010	0.0039
	POP	0.3154	0.3621	0.0374	0.0476	0.2147	0.2220
	MLP	0.0067	0.1239	0.0013	0.0125	0.0012	0.0141
	LightGCN	0.3701	0.4075	0.0640	0.0766	0.1566	0.1108
	ENMF	0.9397	0.9511	<u>0.3781</u>	<u>0.5432</u>	<u>0.7649</u>	0.6227
	ACKRec	0.9694	0.9834	0.1141	0.3489	0.3864	<u>0.8307</u>
	SimpleX	<u>0.9768</u>	<u>0.9842</u>	0.4423	0.6804	0.8782	0.7491
	Ours	0.9843	0.9964	0.1473	0.5100	0.5038	0.9155
	提升 (%)	0.77	1.24	—	—	—	10.21
MOOCCube-mana	ItemCF	0.0216	0.1051	0.0043	0.0113	0.0040	0.0120
	POP	0.1290	0.2386	0.0148	0.0260	0.0724	0.1054
	MLP	0.0115	0.0613	0.0034	0.0100	0.0038	0.0114
	LightGCN	<u>0.9070</u>	0.9249	0.0163	0.0309	0.7425	0.7138
	ENMF	0.8556	0.8882	<u>0.2874</u>	0.4135	<u>0.5915</u>	0.4844
	ACKRec	<u>0.8996</u>	<u>0.9618</u>	0.1103	<u>0.4565</u>	0.3871	<u>0.7279</u>
	SimpleX	0.8918	0.9161	0.3335	<u>0.5016</u>	<u>0.6810</u>	0.5733
	Ours	0.9916	0.9998	0.1463	0.5017	0.4913	0.9068
	提升 (%)	9.33	3.95	—	0.02	—	24.58

其次,主流的深度学习推荐方法 SimpleX、ENMF 与 LightGCN 在所有指标上的性能均优于传统的推荐方法 ItemCF 与 POP,表明了传统的方法受限于自身建模方式的简单性存在表达能力不足的问题,深度学习技术凭借精巧的深度学习模型结构设计,能够有效地挖掘出用户学习行为中的潜在特征,验证了深度学习推荐方法发展的必然性。值得注意的是,MLP 推荐模型虽然是深度学习模型,但是其性能均低于基于统计的 POP 方法。这是由于两个数据集的数据存在高度稀疏的现象,据本文统计,MOOCCube-comp 数据集的数据稀疏性为 74.24%,而 MOOCCube-mana 数据集的数据稀疏性也高达 87.07%。而 MLP 方法模型仅是 3 层简单的全连接层组合结构,且缺乏引入额外特征辅助与序列化建模能力,故在数据极度稀疏的情况下推荐效果不如基于统计的 POP 方法的性能稳定。

最后,除了本文提出的方法,教育领域推荐模型 ACKRec 也展现出具有竞争力的推荐性能,在两个数据集一共 12 个指标结果上超过一半的指标均排名前 3。此外,为了综合地比较教育领域推荐方法与通用推荐方法的稳定性与泛化性,本文对通用的深度学习推荐模型 (SimpleX、SNMF 和 LightGCN) 与教育领域推荐模型 (ACKRec 和本文提出的模型) 在不同数据集上推荐性能的变化趋势进行统计对比,统计结果如图 5 与表 5 所示。图 5 表示模型在两个数据集上相同指标性能的占比情况(百分比堆积柱形图),图上横坐标表示评估指标,纵坐标表示比例。图上的橙色面积或蓝色面积越接近 50%,则表示该模型的指标值在两个数据集上的表现越稳定,模型能够稳定地由一个数据集泛化到另一个数据集中。由图 5 和表 5 的统计结果可得:一方面,本文提出的模型在所有评估指标上的指标变化幅度(橙色面积/蓝色面积与 50% 的比例差距)、平均指标变化幅度(所有指标的橙色面积/蓝色面积与 50% 的比例距离的平均值)与指标变化范围(由最小比例差距和最大比例差距构成的范围区间)基本上均为最小,表明了本文提出的模型具有最优越的稳定性与泛化性,进一步验证了本文提出的模型的有效性。另一方面,相较于通用的深度学习模型,教育领域推荐方法均体现出较小的指标变化幅度、平均指标变化幅度与指标变化范围,本文的方法最优,ACKRec 模型次优,表明了教育领域的推荐方法在教育推荐场景中具有更优的稳定性与泛化性。而通用的深度学习推荐模型虽然存在部分优异的指标结果,但其在教育场景的不同数据集与不同评估指标上均出现

不稳定的表现, 表明了通用的深度学习推荐模型无法有效地解决教育领域的推荐问题。综合表4、图5与表5的实验结果可得, 通用领域的推荐方法缺乏考虑教育领域中的场景特征, 尚未能完全解决教育领域的学习资源推荐面临的问题与挑战。

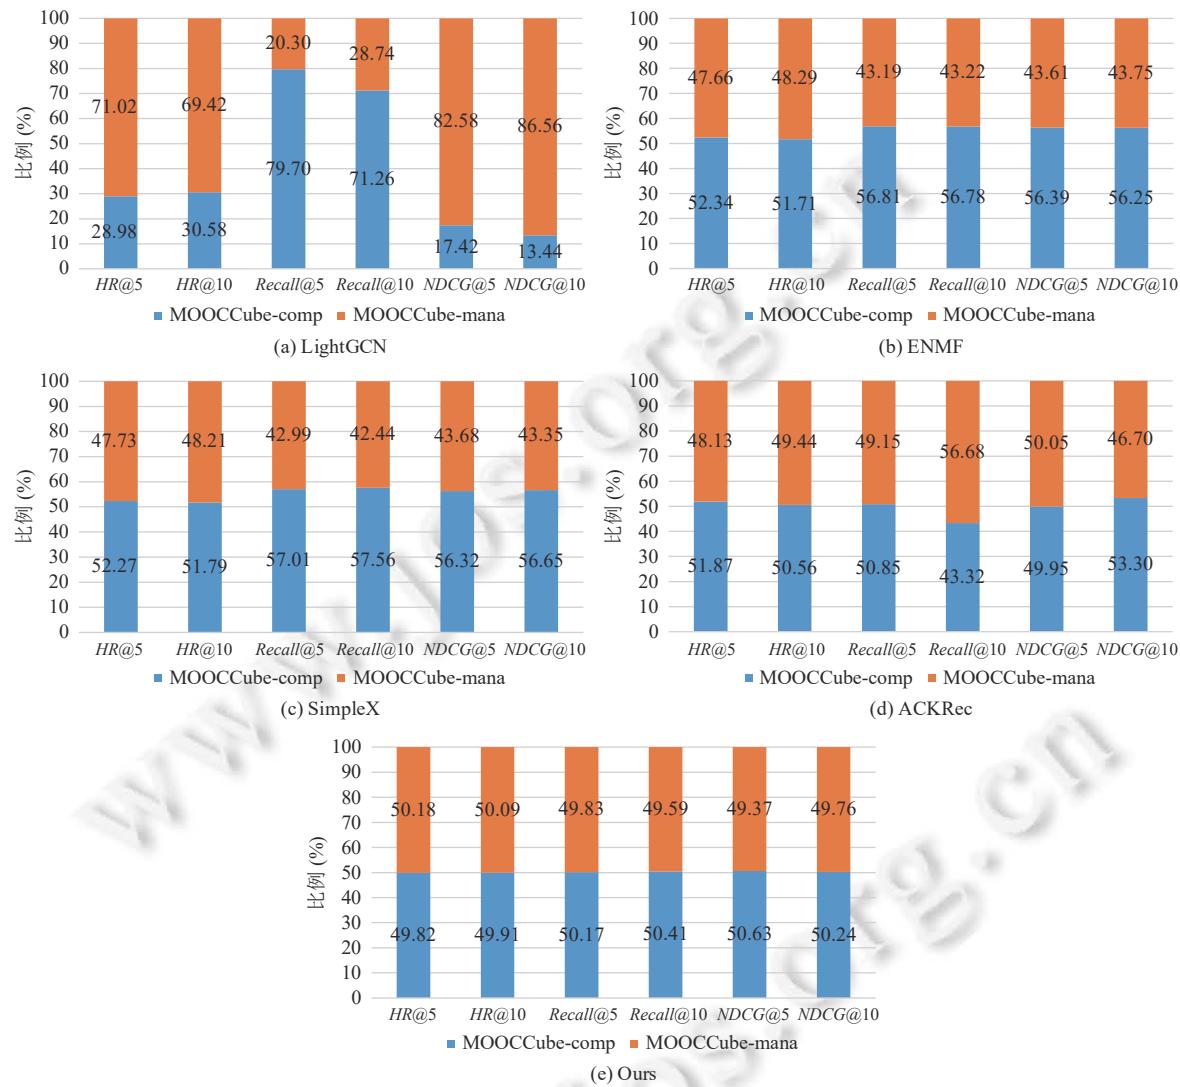


图5 推荐性能稳定性比较

表5 跨数据集的指标变化统计结果(%)

对比模型	指标变化幅度						平均指标变化幅度	指标变化范围
	HR@5	HR@10	Recall@5	Recall@10	NDCG@5	NDCG@10		
LightGCN	21.02	19.42	29.70	21.26	32.58	36.56	26.76	19.42–36.56
ENMF	2.34	1.71	6.81	6.78	6.39	6.25	5.05	1.71–6.81
SimpleX	2.27	1.79	7.01	7.56	6.32	6.65	5.27	1.79–7.56
ACKRec	<u>1.87</u>	<u>0.56</u>	<u>0.85</u>	<u>6.68</u>	0.05	<u>3.30</u>	<u>2.22</u>	<u>0.05</u> –6.68
Ours	0.18	0.09	0.17	0.41	<u>0.63</u>	0.24	0.29	0.09 –0.63

4.5 消融实验分析

本文提出的基于静态与动态学习需求感知的知识点推荐方法主要考虑对用户学习行为中潜在的静态和动态的学习需求同时进行显式地建模,核心的技术创新点有 3 点。①本文首次在知识点推荐任务中引入先修后继知识元路径,通过主流的基于元路径的注意力图卷积网络在信息聚合过程中自然地融合对知识点先修后继关系的建模,以捕获用户全局的静态学习需求;②本文以课程为单元,聚合每个课程中包含的知识点的嵌入来表征用户在不同时刻的知识水平,再引入循环神经网络建模用户不同时刻知识水平的动态变化,以捕获用户个体的动态学习需求;③虽然图卷积网络能够捕获全局的高阶协同信号,但缺乏序列化动态建模的能力,而循环神经网络适用于序列化动态建模的场景,却无法捕获不同个体之间的高阶协同信号,于是本文设计了一个统一的框架对图卷积和循环神经网络进行集成,以获得同时感知静态与动态学习需求的能力。因此,本节主要验证这 3 个技术创新点对推荐性能的影响。由于本文提出的模型是在 ACKRec 模型上的改进,因此本节中将 ACKRec 作为基准模型,简记为 BBN (backbone network)。将在 BBN 基础上仅引入技术创新点①的变体模型记为 BBN+path;将在 BBN 基础上仅引入技术创新点②的变体模型记为 BBN+GRU;将技术创新点③的引入,即本文提出的模型记为 Ours。[表 6](#) 展示了在两个数据集上的消融实验对比结果。

表 6 MOOCCube-comp 数据集上的消融实验结果

数据集	对比模型	HR@5	HR@10	Recall@5	Recall@10	NDCG@5	NDCG@10
MOOCCube-comp	BBN	0.9694	0.9834	0.1141	0.3489	0.3864	0.8307
	BBN+path	0.9476	0.9922	0.0989	0.5109	0.3370	0.8038
	BBN+GRU	0.9822	0.9952	0.1365	0.4812	0.4742	0.8895
	Ours	0.9843	0.9964	0.1473	0.5100	0.5038	0.9155
MOOCCube-mana	BBN	0.8996	0.9618	0.1103	0.4565	0.3871	0.7279
	BBN+path	0.9033	0.9693	0.1186	0.4558	0.3968	0.7290
	BBN+GRU	0.9102	0.9666	0.1372	0.4620	0.4816	0.7378
	Ours	0.9916	0.9998	0.1463	0.5017	0.4913	0.9068

首先,综合[表 6](#)中 BBN+path 变体模型与 BBN 基准模型在两个数据集上的所有对比结果可知, BBN+path 变体模型在绝大多数评估指标上均优于 BBN 基准模型,验证了本文技术创新点①的有效性,即基于先修后继知识元路径引导的注意力图卷积建模能够有效强化静态学习需求的感知能力,从而提升模型推荐的效果。值得注意的是,本文发现在 MOOCCube-comp 数据集上除了 HR@10 与 Recall@10 两个指标以外,在剩下的 4 个指标值上 BBN+path 变体模型的性能均略低于基准模型 BBN,本文认为可能是由于知识点之间存在的其他关联关系干扰了先修后继知识元路径引导注意力图卷积的建模过程,如互补关系或包含关系等,因而导致模型推荐效果略微下降。为了验证这一猜想,本文对两个数据集中平均每个课程包含的知识点数的进行统计,若平均每个课程中包含的知识点越多,则暗示这些知识点之间可能为互补共现关系,而非先修后继关系。据统计,MOOCCube-mana 数据集中平均每个课程包含的知识点数约为 34.44 个,而 MOOCCube-comp 中则约为 53.97 个,其数量约为 MOOCCube-mana 数据集中统计结果的两倍。该统计结果暗示了 MOOCCube-comp 数据集中知识点的互补关系约是 MOOCCube-mana 数据集中知识点互补关系的两倍,所以在对先修后继知识元路径的引导建模形成了噪声干扰,故导致 BBN+path 变体模型在 MOOCCube-comp 数据集中存在部分评估指标略低于 BBN 基准模型的现象。本文将对知识点互补等其他关系的探索留在后续的研究目标。其次,由[表 6](#)可知,在两个数据集中 BBN+GRU 变体模型在所有指标上的性能均优于基准模型 BBN,证明了本文技术创新点②的有效性,即聚合每个课程中包含的知识点嵌入来表征用户在学习完每一门课的知识水平,再通过循环神经网络挖掘用户知识水平动态变化下蕴含的动态学习需求有助于提升模型推荐的效果。除此之外,本文观察到 BBN+GRU 变体模型相较于基准模型 BBN 的性能提升高于 BBN+path 变体模型,这一现象表明了用户的动态学习需求相较于静态学习需求主导了推荐性能的提升,进一步说明了用户动态学习需求感知的重要性。最后,在任意一个数据集上,本文提出的完整模型 Ours 在所有评估指标上均有效击败了变体模型 BBN+path 与 BBN+GRU,验证了本文技术创新点③的有效性,即同时感知用户

的静态学习需求与动态学习需求有助于极大地促进推荐性能的提升, 也表明了对图卷积网络与循环神经网络的集成统一有助于弥补单一模型存在的不足, 起到一加一大于二的效果.

4.6 参数实验分析

为了在测试集上取得最佳的性能且研究不同参数对模型推荐性能的影响, 本文对可能影响模型推荐效果的所有参数在参数空间中进行网格调参, 并通过控制变量法探索模型对不同参数的敏感度. 具体地, 本文从值集范围 [2, 3, 4] 中搜索图卷积网络的层数, 实体的潜在嵌入维度在值集 [10, 20, 30, 40] 中选择最优的维度值, 从值集范围 [20, 50, 100, 150, 200] 中搜索知识点特征初始化的向量维度. 由于篇幅限制, 且通过网格调参发现本文的模型在两个数据集上均体现出相同的现象规律, 因此, 本节仅以 MOOCube-comp 数据集上的实验结果为例进行讨论. 在 MOOCube-comp 数据集上, 本文提出的模型的最优推荐性能在图卷积网络层数为 3、实体的潜在嵌入维度为 30、知识点特征初始化的向量维度为 50 时取到. 接下来, 本节将详细阐述不同参数对本文提出的模型的影响.

(1) 图卷积网络层数. 由于图卷积网络的层数设置会影响到模型对异构知识网络中特征挖掘的深度, 深层的图卷积网络能够挖掘到更加丰富的高阶连通性特征(即协同信号), 进而提升模型的推荐效果. 因此, 本文在值集范围 [2, 3, 4] 中研究图卷积网络层数对模型性能的具体影响. 实验结果如图 6 所示, 随着图卷积网络层数的加深, 本文提出的模型在 6 个评估指标上的综合性能会呈现先上升后下降的趋势. 实验结果表明了图卷积网络的层数有助于模型建模更深层次的语义关联特征, 如高阶连通性等. 同时, 随着层数的加深, 模型聚合到的邻居节点信息会更复杂与繁多, 可能会引入额外的无关噪声特征, 从而降低了推荐模型的性能. 除此之外, 随着图卷积网络层数的增加, 模型的计算复杂度以及计算的时空间成本也会随着增大. 因此, 在真实推荐应用场景中, 推荐模型的设计需要平衡图卷积网络层数与计算成本之间的矛盾, 以在合适的计算成本下取得最优的推荐性能.

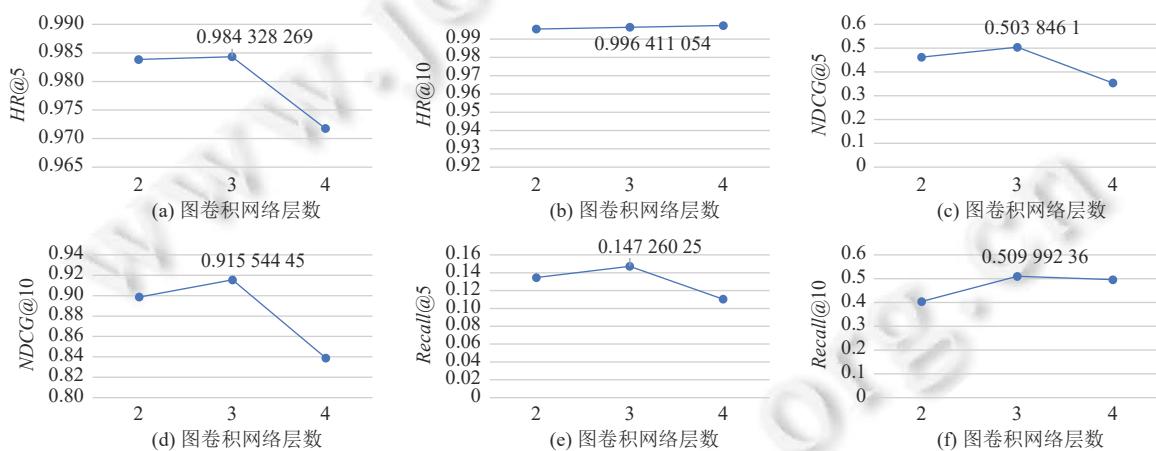


图 6 不同图卷积网络层数的推荐性能

(2) 实体的潜在嵌入维度. 由于在矩阵分解方法中, 实体(用户与知识点)的潜在嵌入维度是影响预测性能的重要参数^[7]. 因此, 本文在值集取值范围 [10, 20, 30, 40] 中研究实体的潜在嵌入维度对模型性能的影响. 实验结果如图 7 所示, 随着实体的潜在嵌入维度的取值的不同, 推荐模型在 6 个评估指标上的综合性能也随着不同. 本文发现当潜在嵌入维度取值为 30 时, 本文所提出的模型取得综合指标上的最优性能. 实验表明了实体的潜在嵌入维度会影响实体嵌入表达向量携带的特征准确度. 过小的潜在嵌入维度可能携带的特征信息不足, 过大的潜在嵌入维度则可能会引入其他噪声特征, 都会降低推荐模型的性能. 因此, 在真实的推荐场景中, 推荐模型的设计需要尝试不同的潜在嵌入维度取值以获得最优的推荐性能.

(3) 知识点特征初始化的向量维度. 由于知识点的名称携带了丰富的语义信息, 采用 Word2Vec 方法生成的知识点嵌入向量的维度大小蕴含的语义信息量不同, 会影响知识点表征的准确性, 进而影响推荐模型的性能. 因此, 本文在值集取值范围 [20, 50, 100, 150, 200] 中研究知识点特征初始化的向量维度对模型性能的影响. 实验结果如图 8

所示,随着知识点特征初始化的向量维度不断变大,本文所提出的模型最开始在 6 个评估指标上的综合性能会随着提高,当向量维度取值超过 100 之后, $HR@5$ 和 $HR@10$ 指标值趋于平稳,而另外 4 个指标随着呈现下降的趋势。实验结果表明了知识点名称的语义特征有助于提高教育领域推荐模型的性能,随着知识点特征初始化向量维度的不断扩大,向量中蕴含的语义特征会更加准确与丰富,同时向量中蕴含的噪声干扰也会增多。因此,同样需要在真实应用场景中灵活地调整知识点特征初始化的向量维度,以取得最优的推荐性能。

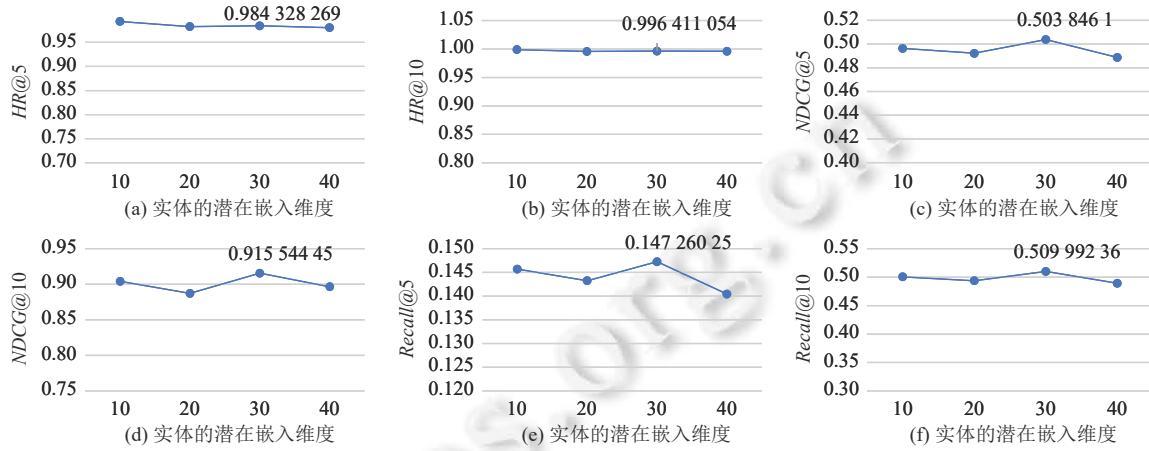


图 7 不同用户与知识点的潜在嵌入维度的推荐性能

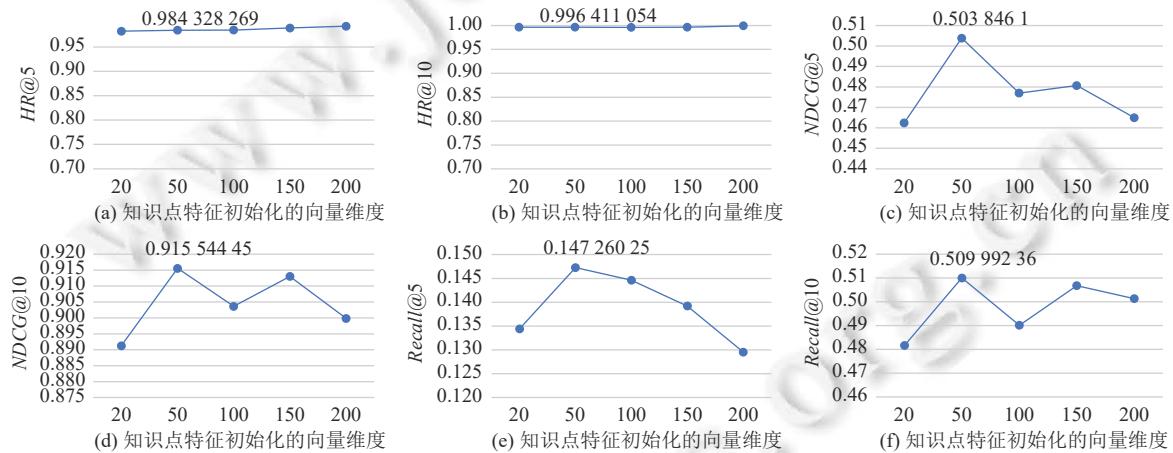


图 8 不同知识点特征初始化向量维度的推荐性能

5 总结与展望

教育领域推荐方法重点研究解决教育场景中用户面临的“信息过载”与“知识迷航”问题,具有十分可观的应用价值。本文提出了一种基于静态与动态学习需求感知的知识点推荐方法,旨在通过静态感知与动态感知相结合的方式建模复杂知识关联下的用户学习行为。首先,针对现有的知识点推荐方法在静态学习需求感知时忽略了对知识点之间复杂关系进行建模的问题,本文创新性地提出了一种基于先修后继知识元路径引导的注意力图卷积网络,通过在建模中补充知识点先修后继关系的引导,以精炼用户的静态学习需求。其次,针对现有的知识点推荐方法缺乏对用户学习需求的动态特性进行挖掘的问题,本文以课程为单元聚合知识点嵌入表达来编码用户在不同时间阶段的知识水平,然后采用门控循环单元网络对用户在不同时间阶段的知识水平进行序列化建模,以捕获用户

的动态学习需求。最后,本文在同一框架下建模静态与动态学习需求之间的兼容性,促进这两种学习需求相互补充与融合,以实现细粒度的个性化知识点推荐。大量实验表明,本文提出的知识点推荐方法在多种指标上优于一系列先进的推荐方法,验证了本文提出的方法的有效性与先进性。

除了上述的研究工作,本文提出的方法仍存在很多提升空间。在学习需求挖掘方面,本文仅采用一阶的先修后继知识元路径引导学习需求的显式建模,可考虑补充高阶的先修后继关系元路径以及互补等其他关系元路径以挖掘更加精准的用户学习需求。另一方面,数据稀疏性问题是困扰推荐系统多年的一个开放性问题,在教育推荐场景中存在多种用户的交互行为,如点击、收藏、观看时长与评论等,综合多种交互行为以挖掘用户的学习需求,是一种具有前景的能够有效应对教育推荐场景中数据稀疏性问题的研究方向。

References:

- [1] Zhong L, Wei YT, Yao H, Deng W, Wang ZF, Tong MW. Review of deep learning-based personalized learning recommendation. In: Proc. of the 11th Int'l Conf. on E-education, E-business, E-management, and E-learning. Osaka: Association for Computing Machinery, 2020. 145–149. [doi: [10.1145/3377571.3377587](https://doi.org/10.1145/3377571.3377587)]
- [2] Shen M, Lai TP, Wang SM, Peng YM, Gao ZT. Design and implementation of the course recommendation engine in Peking University. CAAI Trans. on Intelligent Systems, 2015, 10(3): 369–375 (in Chinese with English abstract). [doi: [10.3969/j.issn.1673-4785.201409045](https://doi.org/10.3969/j.issn.1673-4785.201409045)]
- [3] Song XL, He LW. Online course recommendation model based on enhanced auto-encoder. Computer Systems & Applications, 2022, 31(3): 288–293 (in Chinese with English abstract). [doi: [10.15888/j.cnki.csa.008356](https://doi.org/10.15888/j.cnki.csa.008356)]
- [4] Dai J, Li QS, Chu H, Zhou YT, Yang WY, Wei BB. Breakthrough in smart education: Course recommendation system based on graph learning. Ruan Jian Xue Bao/Journal of Software, 2022, 33(10): 3656–3672 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6629.htm> [doi: [10.13328/j.cnki.jos.006629](https://doi.org/10.13328/j.cnki.jos.006629)]
- [5] Zhu YF, Lu H, Qiu P, Shi KZ, Chambua J, Niu ZD. Heterogeneous teaching evaluation network based offline course recommendation with graph learning and tensor factorization. Neurocomputing, 2020, 415: 84–95. [doi: [10.1016/j.neucom.2020.07.064](https://doi.org/10.1016/j.neucom.2020.07.064)]
- [6] Chen X, Sun YH, Ding CQ, Liu LC. An online course recommendation method enhanced by knowledge graph. Software Guide, 2022, 21(1): 9–14 (in Chinese with English abstract). [doi: [10.11907/rjdc.212588](https://doi.org/10.11907/rjdc.212588)]
- [7] Gong JB, Wang S, Wang JL, Feng WZ, Peng H, Tang J, Yu PS. Attentional graph convolutional networks for knowledge concept recommendation in MOOCs in a heterogeneous view. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Association for Computing Machinery, 2020. 79–88. [doi: [10.1145/3397271.3401057](https://doi.org/10.1145/3397271.3401057)]
- [8] Wang C, Zhu HS, Zhu C, Zhang X, Chen EH, Xiong H. Personalized employee training course recommendation with career development awareness. In: Proc. of the 2020 Web Conf. Taipei: Association for Computing Machinery, 2020. 1648–1659. [doi: [10.1145/3366423.3380236](https://doi.org/10.1145/3366423.3380236)]
- [9] Goldberg D, Nichols D, Oki BM, Terry D. Using collaborative filtering to weave an information tapestry. Communications of the ACM, 1992, 35(12): 61–70. [doi: [10.1145/138859.138867](https://doi.org/10.1145/138859.138867)]
- [10] Linden G, Smith B, York J. Amazon. com recommendations: Item-to-item collaborative filtering. IEEE Internet Computing, 2003, 7(1): 76–80. [doi: [10.1109/MIC.2003.1167344](https://doi.org/10.1109/MIC.2003.1167344)]
- [11] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems. Computer, 2009, 42(8): 30–37. [doi: [10.1109/CMC.2009.263](https://doi.org/10.1109/CMC.2009.263)]
- [12] Wang Z. Deep Learning Recommender System. Beijing: Publishing House of Electronics Industry, 2020. 50–100 (in Chinese).
- [13] He XN, Liao LZ, Zhang HW, Nie LQ, Hu X, Chua TS. Neural collaborative filtering. In: Proc. of the 26th Int'l Conf. on World Wide Web. Perth: Int'l World Wide Web Conf. Steering Committee, 2017. 173–182. [doi: [10.1145/3038912.3052569](https://doi.org/10.1145/3038912.3052569)]
- [14] van den Berg R, Kipf TN, Welling M. Graph convolutional matrix completion. In: Proc. of the 24th ACM Int'l Conf. on Knowledge Discovery and Data Mining. London: Association for Computing Machinery, 2018. 9.
- [15] He XN, Deng K, Wang X, Li Y, Zhang YD, Wang M. LightGCN: Simplifying and powering graph convolution network for recommendation. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2020. 639–648. [doi: [10.1145/3397271.3401063](https://doi.org/10.1145/3397271.3401063)]
- [16] Zhou GR, Zhu XQ, Song CR, Fan Y, Zhu H, Ma X, Yan YH, Jin JQ, Li H, Gai K. Deep interest network for click-through rate prediction. In: Proc. of the 24th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining. London: Association for Computing Machinery, 2018. 1059–1068. [doi: [10.1145/3219819.3219823](https://doi.org/10.1145/3219819.3219823)]
- [17] Zhou GR, Mou N, Fan Y, Pi Q, Bian WJ, Zhou C, Zhu XQ, Gai K. Deep interest evolution network for click-through rate prediction. In:

- Proc. of the 33rd AAAI Conf. on Artificial Intelligence. Honolulu: AAAI, 2019. 5941–5948. [doi: [10.1609/aaai.v33i01.33015941](https://doi.org/10.1609/aaai.v33i01.33015941)]
- [18] Tian Y, Chang JX, Niu YN, Song Y, Li CL. When multi-level meets multi-interest: A multi-grained neural model for sequential recommendation. In: Proc. of the 45th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Madrid: Association for Computing Machinery, 2022. 1632–1641. [doi: [10.1145/3477495.3532081](https://doi.org/10.1145/3477495.3532081)]
- [19] Chen C, Zhang M, Zhang YF, Liu YQ, Ma SP. Efficient neural matrix factorization without sampling for recommendation. ACM Trans. on Information Systems, 2020, 38(2): 14. [doi: [10.1145/3373807](https://doi.org/10.1145/3373807)]
- [20] Mao KL, Zhu JM, Wang JP, Dai QY, Dong ZH, Xiao X, He XQ. SimpleX: A simple and strong baseline for collaborative filtering. In: Proc. of the 30th ACM Int'l Conf. on Information & Knowledge Management. Queensland: Association for Computing Machinery, 2021. 1243–1252. [doi: [10.1145/3459637.3482297](https://doi.org/10.1145/3459637.3482297)]
- [21] Shi C, Hu BB, Zhao WX, Yu PS. Heterogeneous information network embedding for recommendation. IEEE Trans. on Knowledge and Data Engineering, 2019, 31(2): 357–370. [doi: [10.1109/TKDE.2018.2833443](https://doi.org/10.1109/TKDE.2018.2833443)]
- [22] Wang ZK, Liu HZ, Du YP, Wu ZH, Zhang X. Unified embedding model over heterogeneous information network for personalized recommendation. In: Proc. of the 28th Int'l Joint Conf. on Artificial Intelligence. Macao: IJCAI.org, 2019. 3813–3819. [doi: [10.24963/ijcai.2019/529](https://doi.org/10.24963/ijcai.2019/529)]
- [23] Wu H, Xu XJ, Meng FJ. Knowledge graph-assisted multi-task feature-based course recommendation algorithm. Computer Engineering and Applications, 2021, 57(21): 132–139 (in Chinese with English abstract). [doi: [10.3778/j.issn.1002-8331.2010-0287](https://doi.org/10.3778/j.issn.1002-8331.2010-0287)]
- [24] Wang Y, Zhu MX, Yang SH, Lu XS, Zhou AY. Review and performance comparison of deep knowledge tracing models. Ruan Jian Xue Bao/Journal of Software, 2023, 34(3): 1365–1395 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6715.htm> [doi: [10.13328/j.cnki.jos.006715](https://doi.org/10.13328/j.cnki.jos.006715)]
- [25] Jiang WJ, Pardos ZA, Wei Q. Goal-based course recommendation. In: Proc. of the 9th Int'l Conf. on Learning Analytics & Knowledge. Tempe: Association for Computing Machinery, 2019. 36–45. [doi: [10.1145/3303772.3303814](https://doi.org/10.1145/3303772.3303814)]
- [26] Zhao JJ, Bhatt S, Thille C, Zimmaro D, Gattani N. Interpretable personalized knowledge tracing and next learning activity recommendation. In: Proc. of the 7th ACM Conf. on Learning@Scale. New York: Association for Computing Machinery, 2020. 325–328. [doi: [10.1145/3386527.3406739](https://doi.org/10.1145/3386527.3406739)]
- [27] Wang SJ, Hu L, Wang Y, Sheng QZ, Orgun M, Cao LB. Intention2Basket: A neural intention-driven approach for dynamic next-basket planning. In: Proc. of the 29th Int'l Joint Conf. on Artificial Intelligence. Yokohama: ijcai.org, 2021. 2333–2339. [doi: [10.24963/ijcai.2020/323](https://doi.org/10.24963/ijcai.2020/323)]
- [28] Nabizadeh AH, Leal JP, Rafsanjani HN, Shah RR. Learning path personalization and recommendation methods: A survey of the state-of-the-art. Expert Systems with Applications, 2020, 159: 113596. [doi: [10.1016/j.eswa.2020.113596](https://doi.org/10.1016/j.eswa.2020.113596)]
- [29] Mikolov T, Chen K, Corrado G, Dean J. Efficient estimation of word representations in vector space. In: Proc. of the 1st Int'l Conf. on Learning Representations. Scottsdale: ICLR, 2013.
- [30] Li XG, Wei SQ, Zhang X, Du YF, Yu G. LFKT: Deep knowledge tracing model with learning and forgetting behavior merging. Ruan Jian Xue Bao/Journal of Software, 2021, 32(3): 818–830 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6185.htm> [doi: [10.13328/j.cnki.jos.006185](https://doi.org/10.13328/j.cnki.jos.006185)]
- [31] Yu F, Liu Q, Wu S, Wang L, Tan TN. A dynamic recurrent model for next basket recommendation. In: Proc. of the 39th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Pisa: Association for Computing Machinery, 2016. 729–732. [doi: [10.1145/2911451.2914683](https://doi.org/10.1145/2911451.2914683)]
- [32] Qin YQ, Wang PF, Li CL. The world is binary: Contrastive learning for denoising next basket recommendation. In: Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Association for Computing Machinery, 2021. 859–868. [doi: [10.1145/3404835.3462836](https://doi.org/10.1145/3404835.3462836)]
- [33] Fang H, Zhang DN, Shu YH, Guo GB. Deep learning for sequential recommendation: Algorithms, influential factors, and evaluations. ACM Trans. on Information Systems, 2020, 39(1): 10. [doi: [10.1145/3426723](https://doi.org/10.1145/3426723)]
- [34] Hidasi B, Karatzoglou A, Baltrunas L, Tikk D. Session-based recommendations with recurrent neural networks. In: Proc. of the 4th Int'l Conf. on Learning Representations. San Juan: ICLR, 2016.
- [35] Yu JF, Luo G, Xiao T, Zhang QY, Wang YQ, Feng WZ, Luo JY, Wang CY, Hou L, Li JZ, Liu ZY, Tang J. MOOCube: A large-scale data repository for NLP applications in MOOCs. In: Proc. of the 58th Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2020. 3135–3142. [doi: [10.18653/v1/2020.acl-main.285](https://doi.org/10.18653/v1/2020.acl-main.285)]
- [36] Bai T, Nie JY, Zhao WX, Zhu YT, Du P, Wen JR. An attribute-aware neural attentive model for next basket recommendation. In: Proc. of the 41st Int'l ACM SIGIR Conf. on Research & Development in Information Retrieval. Ann Arbor: Association for Computing Machinery, 2018. 1201–1204. [doi: [10.1145/3209978.3210129](https://doi.org/10.1145/3209978.3210129)]

- [37] Zhang YZ, Luo L, Zhang JJ, Lu Q, Wang Y, Wang ZY. Correlation-aware next basket recommendation using graph attention networks. In: Proc. of the 27th Int'l Conf. on Neural Information Processing. Bangkok: Springer, 2020. 746–753. [doi: [10.1007/978-3-030-63820-7_85](https://doi.org/10.1007/978-3-030-63820-7_85)]
- [38] Shao EZ, Guo SY, Pardos ZA. Degree planning with PLAN-BERT: Multi-semester recommendation using future courses of interest. In: Proc. of the 35th AAAI Conf. on Artificial Intelligence. AAAI, 2021. 14920–14929. [doi: [10.1609/aaai.v35i17.17751](https://doi.org/10.1609/aaai.v35i17.17751)]
- [39] Hu HJ, He XN, Gao JY, Zhang ZL. Modeling personalized item frequency information for next-basket recommendation. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. New York: Association for Computing Machinery, 2020. 1071–1080. [doi: [10.1145/3397271.3401066](https://doi.org/10.1145/3397271.3401066)]
- [40] Zhao WX, Mu SL, Hou YP, Lin ZH, Chen YS, Pan XY, Li KY, Lu YJ, Wang H, Tian CX, Min YQ, Feng ZC, Fan XY, Chen X, Wang PF, Ji WD, Li YL, Wang XL, Wen JR. RecBole: Towards a unified, comprehensive and efficient framework for recommendation algorithms. In: Proc. of the 30th ACM Int'l Conf. on Information & Knowledge Management. New York: Association for Computing Machinery, 2021. 4653–4664. [doi: [10.1145/3459637.3482016](https://doi.org/10.1145/3459637.3482016)]

附中文参考文献:

- [2] 沈苗, 来天平, 王素美, 彭一明, 高志同. 北京大学课程推荐引擎的设计和实现. 智能系统学报, 2015, 10(3): 369–375. [doi: [10.3969/j.issn.1673-4785.201409045](https://doi.org/10.3969/j.issn.1673-4785.201409045)]
- [3] 宋晓丽, 贺龙威. 基于改进自编码器的在线课程推荐模型. 计算机系统应用, 2022, 31(3): 288–293. [doi: [10.15888/j.cnki.csa.008356](https://doi.org/10.15888/j.cnki.csa.008356)]
- [4] 罗杰, 李青山, 褚华, 周洋涛, 杨文勇, 卫彪彪. 突破智慧教育: 基于图学习的课程推荐系统. 软件学报, 2022, 33(10): 3656–3672. <http://www.jos.org.cn/1000-9825/6629.htm> [doi: [10.13328/j.cnki.jos.006629](https://doi.org/10.13328/j.cnki.jos.006629)]
- [6] 徐欣, 孙玉虹, 丁长青, 刘利聪. 一种知识图谱增强的在线课程推荐方法. 软件导刊, 2022, 21(1): 9–14. [doi: [10.11907/rjdc.212588](https://doi.org/10.11907/rjdc.212588)]
- [12] 王喆. 深度学习推荐系统. 北京: 电子工业出版社, 2020. 50–100.
- [23] 吴昊, 徐行健, 孟繁军. 课程资源的融合知识图谱多任务特征推荐算法. 计算机工程与应用, 2021, 57(21): 132–139. [doi: [10.3778/j.issn.1002-8331.2010-0287](https://doi.org/10.3778/j.issn.1002-8331.2010-0287)]
- [24] 王宇, 朱梦霞, 杨尚辉, 陆雪松, 周傲英. 深度知识追踪模型综述和性能比较. 软件学报, 2023, 34(3): 1365–1395. <http://www.jos.org.cn/1000-9825/6715.htm> [doi: [10.13328/j.cnki.jos.006715](https://doi.org/10.13328/j.cnki.jos.006715)]
- [30] 李晓光, 魏思齐, 张昕, 杜岳峰, 于戈. LFKT: 学习与遗忘融合的深度知识追踪模型. 软件学报, 2021, 32(3): 818–830. <http://www.jos.org.cn/1000-9825/6185.htm> [doi: [10.13328/j.cnki.jos.006185](https://doi.org/10.13328/j.cnki.jos.006185)]



周洋涛(1998—), 男, 博士生, 主要研究领域为推荐系统, 数据挖掘, 知识图谱.



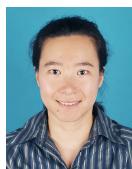
李佳楠(1991—), 女, 博士, 讲师, 主要研究领域为视频行为识别, 图像及视频理解, 推荐系统.



李青山(1973—), 男, 博士, 教授, 博士生导师, CCF 杰出会员, 主要研究领域为大数据智能化分析技术, 智能软件工程.



高明彪(2000—), 男, 硕士生, 主要研究领域为推荐系统, 知识图谱.



褚华(1977—), 女, 博士, 副教授, 主要研究领域为面向对象技术, 软件工程, 推荐系统.



卫彪彪(1999—), 男, 硕士生, 主要研究领域为推荐系统, 智能问答.