

## 基于超图神经网络与动态知识追踪融合的学习路径推荐

刘美麟, 马乐

引用本文

刘美麟, 马乐. 基于超图神经网络与动态知识追踪融合的学习路径推荐[J]. 计算机科学, 2026, 53(5): 68-78.

LIU Meilin, MA Le. [Learning Path Recommendation Based on Fusion of Hypergraph Neural Network and Dynamic Knowledge Tracking](#) [J]. Computer Science, 2026, 53(5): 68-78.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

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

### [基于无冲突路径算法的多目标智能仓储路径规划](#)

Multi-objective Intelligent Warehousing Path Planning Based on Conflict Free Path Algorithm  
计算机科学, 2026, 53(4): 88-100. <https://doi.org/10.11896/jsjcx.250200035>

### [基于目标相似性驱动与双端变量引导搜索的大规模多目标进化算法](#)

Large-scale Multi-objective Evolutionary Algorithm Based on Objective Similarity and Dual-End Variable Guided Search  
计算机科学, 2026, 53(3): 351-365. <https://doi.org/10.11896/jsjcx.250200091>

### [融合多视角习题表征与遗忘机制的深度知识追踪](#)

Multi-view Exercise Representation and Forgetting Mechanism for Deep Knowledge Tracing  
计算机科学, 2026, 53(3): 107-114. <https://doi.org/10.11896/jsjcx.250700092>

### [基于多目标优化的大规模Hadoop集群虚拟机放置](#)

Multi-objective Optimization for Virtual Machine Placement in Large-scale Hadoop Cluster  
计算机科学, 2026, 53(2): 387-395. <https://doi.org/10.11896/jsjcx.241200020>

### [数据空间中基于纠删码的数据布局策略](#)

Data Placement Strategy Based on Erasure Code in Data Space  
计算机科学, 2026, 53(2): 196-206. <https://doi.org/10.11896/jsjcx.241200199>

# 基于超图神经网络与动态知识追踪融合的学习路径推荐

刘美麟 马乐

重庆大学自动化学院 重庆 400044

(1400325886@qq.com)

**摘要** 针对现有学习路径推荐方法在个性化适配性、动态适应性以及多目标优化方面的不足,提出一种基于超图神经网络与知识追踪的协同推荐模型。通过构建学习资源无向图编码资源关联关系,生成学习资源嵌入向量,并结合超图神经网络聚合学习者历史行为数据,捕获学习者-学习资源交互特征。设计多目标优化策略,利用非支配排序遗传算法(NSGA-II)生成帕累托前沿解集,同步优化学习路径推荐精准性、难度适配性、有效性与学习资源多样性,并结合权重分配与综合效用函数提升学习路径的质量。在MOOCube与MOOPer数据集上对所提方法进行实验,其在MOOPer数据集上的HR@5与MRR@5分别达93.9%与90.7%,实现了学习路径的精准推荐。实验结果验证了所提模型在学习者历史交互建模与课程结构约束融合方面的有效性。

**关键词**:学习路径推荐;超图神经网络;知识追踪;多目标优化;权重分配

**中图分类号** TP391;TP183

## Learning Path Recommendation Based on Fusion of Hypergraph Neural Network and Dynamic Knowledge Tracking

LIU Meilin and MA Le

School of Automation, Chongqing University, Chongqing 400044, China

**Abstract** Aiming at the deficiencies of the existing learning path recommendation methods in personalized adaptability, dynamic adaptability and multi-objective optimization, a collaborative recommendation model based on hypergraph neural network and knowledge tracking is proposed. By constructing an undirected graph of learning resources to encode the association relationship of resources, generating the embedding vectors of learning resources, and combining with the hypergraph neural network to aggregate the historical behavior data of learners, the interaction features between learners and learning resources are captured. It designs a multi-objective optimization strategy, utilizes the non-dominated sorting genetic algorithm(NSGA-II) to generate the Pareto frontier solution set, synchronously optimizes the accuracy, difficulty adaptability, effectiveness and diversity of learning resources of the learning path, and combines weight distribution and comprehensive utility function to improve the quality of the learning path. Experiments show that the proposed method is tested on the MOOCube and MOOPer datasets. Among them, the HR@5 and MRR@5 of the MOOPer data reach 93.9% and 90.7% respectively, achieving precise recommendation of learning paths and verifying the effectiveness of the model in the modeling of learners' historical interactions and the integration of course structure constraints.

**Keywords** Learning path recommendation, Hypergraph neural network, Knowledge tracking, Multi-objective optimization, Weight allocation

### 1 引言

随着人工智能、大数据和深度学习等前沿技术的深度渗透,教育领域的数字化转型进程显著加速<sup>[1]</sup>。在线学习平台凭借其开放性、灵活性和学习资源多样性的优势,已成为构建终身学习体系的核心载体。然而,在知识呈指数级增长的

数字化时代,平台在突破时空限制的同时也暴露出结构性矛盾:1)传统课堂实时监督机制的缺失导致信息过载困境,学习者面对海量异构学习资源时难以建立有效的知识依赖图谱;2)静态推荐策略与动态演化的学习者能力模型失配,造成学习路径偏离认知发展轨迹,学习者面临知识迷失的风险<sup>[2-3]</sup>。

教育大数据的深度挖掘为这一困局提供了技术突破口。

到稿日期:2025-06-24 返修日期:2025-07-20

基金项目:国家自然科学基金青年科学基金(62207006);重庆市高等教育学会高等教育科学研究课题(cqgj23002C)

This work was supported by the Young Scientists Fund of the National Natural Science Foundation of China(62207006) and Science Research Project of Higher Education of the Association of Higher Education of Chongqing(cqgj23002C).

通信作者:马乐(maryma@cqu.edu.cn)

通过融合多源学习行为数据与学习资源语义特征,智能教育系统正逐步实现从标准化服务向个性化自适应的演进<sup>[4]</sup>。在此背景下,个性化学习路径推荐利用学习者、学习资源、领域知识特征等信息,为个体定制符合认知规律且契合学习目标的最优知识单元序列。该技术不仅能够促进知识的主动建构与迁移内化,更成为提升学习效果与学习者满意度的关键研究方向<sup>[5]</sup>。

当前,主流推荐算法主要涵盖协同过滤、基于内容、上下文感知及其混合模式。其中,协同过滤技术虽具备计算效率高、通用性强等优势,但在教育资源数据呈指数级增长的现实场景中,其固有的数据稀疏性与冷启动问题导致推荐效果欠佳<sup>[6]</sup>。基于内容的推荐方法虽能缓解稀疏性问题,却因无法有效挖掘学习者-学习资源的隐性交互特征而陷入推荐僵化困境<sup>[7-8]</sup>。值得注意的是,尽管知识图谱嵌入<sup>[9]</sup>与深度神经网络<sup>[10]</sup>等技术已取得阶段性进展,但是现有方法仍受限于两大核心瓶颈:1)高阶关系建模缺失,难以捕捉多学习资源联合作用对知识掌握度的复合影响;2)动态决策机制的缺失导致适应性不强,具体表现在强化学习框架下的路径推荐系统在薄弱知识点识别上存在偏差以及推荐准确性不足等<sup>[11]</sup>。

针对上述挑战,本文创新性地提出融合超图神经网络与动态知识追踪的自适应学习路径推荐模型。核心贡献体现在:1)构建超图-图混合表征模型,通过静态关系图刻画学习资源的语义关联,利用超图建模学习者-学习资源的高阶交互,突破传统图模型边类型单一的理论局限;2)构建图增强型知识追踪机制,通过动态捕捉学习者认知状态与学习资源难度属性的协同演化规律,实现知识掌握度的细粒度感知;3)设计多目标优化过程,同时优化学习者偏好、学习资源匹配度、学习增益及多样性目标,并构建综合效用函数集成多维指标,通过权重调节机制满足学习者分阶段的个性化需求,最终实现学习路径的自适应生成与持续优化。此外,对系统各主要模块的复杂度进行了分析。实验结果表明,本文提出的超图-图混合表征结构融合动态知识感知与多目标决策的推荐模型,在提升学习路径个性化适配性和加强对学习者认知发展支持方面取得了显著效果,为解决个性化推荐不足和认知支撑薄弱等问题提供了有效的解决方案。

## 2 相关工作

### 2.1 学习者-学习资源交互表征

在线学习平台中学习者与学习资源的交互数据为学习资源建模提供了重要支撑,可用于分析资源特征以及学习者偏好。挖掘历史交互行为中学习者-学习资源或学习资源-学习资源间的潜在关系,是学习资源建模的关键<sup>[12]</sup>。图神经网络(Graph Neural Network, GNN)在处理非欧几里德数据特征学习方面取得显著进展<sup>[13]</sup>,推动了相关研究。Wang等<sup>[14]</sup>提出的 NGCF 模型首次将图卷积网络(Graph Convolutional Network, GCN)引入推荐算法,实现了用户与物品间高阶连接的建模。

现有方法通常以学习者和学习资源为节点构建二部图,将推荐任务转换为链路预测问题<sup>[12]</sup>。例如, Xia等<sup>[15]</sup>引入多实体知识图谱刻画学习行为传播规律,增强了上下文感知能

力,但未考虑先修关系等逻辑约束,易产生违背认知顺序的路径推荐。针对这一问题,有学者利用图结构显式建模知识依赖关系,优化推荐逻辑<sup>[16]</sup>。例如, Wang等<sup>[17]</sup>提出了一种基于超边的图神经网络(HGNN),通过超边同时建模学习者关系与课程序列模式,在 MOOC 课程推荐中表现优异; Zhang等<sup>[18]</sup>提出了一种基于图卷积网络的方法,用于对知识图谱上的高阶相关性进行建模,以更准确地捕捉学习者的偏好。

现有模型通常是单维度关系建模,这种机制难以捕捉课程间的多阶关联。对于现有方法普遍存在关系建模不足的问题,本文构建超图-图混合表征模型,使用 GCN 处理静态资源关系图,对学习资源之间的相关性进行建模,并采用顺序超图捕捉学习者-学习资源高阶交互,同时突破传统图模型边类型单一的理论局限。

除此之外,现有研究多数存在动态适配不足、静态模型难以捕捉学习者认知状态与知识掌握度实时演化的问题。采用 RNN(Recurrent Neural Networks)或 Transformer 等序列模型可捕捉学习者行为时序特征和演化趋势,并且可以将时间、地点等上下文信息等多模态数据与学习者行为数据进行融合,更好地理解学习者的行为和需求<sup>[19]</sup>。

例如, Zhang等<sup>[20]</sup>结合递归神经网络和内容技术,通过学习者课程序列提取兴趣特征,实现了更精确的课程推荐。Zhou等<sup>[21]</sup>基于学习者特征相似性聚类,并训练 LSTM(Long Short-Term Memory)模型预测学习路径与表现,所提方法从准确性和效率方面显著提高了学习结果。Zhou等<sup>[22]</sup>借助注意力图卷积网络捕捉知识点静态需求,利用循环神经网络挖掘知识变化中的动态需求,实现了个性化知识点的精准推荐。强化学习方法在动态适配领域展现出优势。Fan等<sup>[11]</sup>将知识点覆盖度与难度系数融入深度强化学习框架,提高了学习路径的有效性和适应性。但现有序列建模方法无法同时捕获表征学习空间上的多粒度信息和学习者在学习过程中的学习兴趣模式变化<sup>[23]</sup>。

Sun等<sup>[24]</sup>提出了记忆增强的顺序超图注意网络(MSH-GAT)模型用于信息扩散预测任务,该模型不仅从友谊网络中学习用户的全局依赖关系,而且设计了顺序超图注意力网络来学习用户和级联之间的短期交互,提升了信息扩散预测的精度。本文在此模型基础上引入双通道 GRU(Gated Recurrent Unit)机制与 Transformer 编码器,协同建模学习者短期知识波动与长期行为演进,用于学习路径推荐任务;同时保留图神经网络处理学习资源静态关系缓解冷启动的优势,并结合超图的高阶关系建模能力,有效捕获学习者行为模式及偏好。该模型结合表征学习空间上多粒度信息的静态特征与学习者在课程上的学习兴趣模式变化的动态特征,生成符合其偏好的个性化学习路径。

### 2.2 认知状态建模

知识追踪技术通过分析学习者作答序列预测其对知识点的掌握状况。当前主流方法包括基于机器学习的贝叶斯知识追踪模型和基于深度学习的知识追踪模型<sup>[25]</sup>。

针对贝叶斯知识追踪模型难以反映学习者知识状态演变、深度知识追踪(Deep Knowledge Tracing, DKT)可解释性差的缺陷, Su等<sup>[26]</sup>提出了练习增强循环神经网络(Exercise-

Enhanced Recurrent Neural Network, EERNN)。该模型使用双向 LSTM 模块从问题文本中提取每个问题的表示,然后通过使用另一个 LSTM 模块将当前回答的问题表示与先前回答的问题表示结合,追踪学习者的知识状态。

Nakagawa 等<sup>[27]</sup>提出了一种基于 GNN 的知识追踪方法,将知识结构转换为图形,将知识跟踪任务重新表述为 GNN 中的时间序列节点级分类问题,提高了对学生表现的预测和可解释性。

Song 等<sup>[28]</sup>提出的基于联合图卷积网络的深度知识追踪(Joint Graph Convolutional Network Based Deep Knowledge Tracing, JKT)框架,通过一个联合图卷积网络挖掘“练习-概念”关系图中的深层隐式信息,在跨概念下的练习之间建立联系,在捕获高级语义信息的同时,提高了模型的可解释性。

本文通过构建静态学习资源关系图来提高模型的可解释性,采用 GCN 获取学习资源间的高阶关系,并结合 LSTM 网络对学习者的历史答题记录进行建模,动态捕捉学习者认知状态与学习资源难度属性的协同演化规律,挖掘知识变化中的动态需求,实现动态知识追踪与准确率预测。

### 2.3 多目标推荐与个性化路径规划

个性化学习路径推荐需要兼顾学习资源的多样性,以满足不同的学习目标<sup>[29]</sup>。然而,现有个性化学习路径推荐方法大多目标维度单一:专注于学习者的偏好,而忽略学习资源之间的关系、学习资源的难度,以及无法满足多样性、可解释性等教育场景的核心诉求<sup>[30]</sup>。

针对上述问题,多位研究者给出了解决方案。如 Huang 等<sup>[31]</sup>提出了一种新的深度强化学习框架,设计了多个优化目标和新的奖励函数,包括复习与探索、难度平稳性和参与度,自适应地向学生推荐合适的练习。

Elshani 等<sup>[32]</sup>利用遗传算法对学习对象的难度级别、持续时间、评分和每个学习对象之间的关系程度来优化学习路径顺序,提升了个性化学习路径的质量。

Ren 等<sup>[33]</sup>提出的 MulOER-SAN 二维多目标框架,利用自注意力网络进行习题推荐,通过底层自注意力机制预测下一习题的知识覆盖,并在顶层根据预测结果筛选出难度和新鲜性合适的候选习题集,采用混沌麻雀搜索算法增强推荐结果的多样性,并引入难度平滑因子以生成高质量排名列表。

虽然许多研究者已经实现了多个目标优化,但多数研究

未突破“准确率-多样性”的权衡困境。本文通过知识状态构建多目标优化过程,在考虑学习者偏好的同时,优化学习路径的难度适应性、学习有效性以及多样性,并在此基础上设计了综合效用函数,通过调节参数适应不同阶段的学习过程,为个性化学习路径推荐提供了新思路。

## 3 学习路径推荐模型

### 3.1 问题定义

设学习者集合  $\mathcal{U} = \{u_1, u_2, \dots, u_m\}$ , 学习资源集合  $\mathcal{R} = \{r_1, r_2, \dots, r_n\}$ , 历史交互记录  $\mathcal{H} = \{(u_i, r_j, t_k, c_k)\}$ , 其中  $t_k$  为时间戳,  $c_k$  为答题情况,  $|\mathcal{H}| = S$ 。

将学习资源  $\mathcal{R}$  作为图节点, 资源间的逻辑依赖关系作为边  $\mathcal{E}$ , 构建无向图  $G_s = (\mathcal{R}, \mathcal{E}_s)$ , 其中  $(r_i, r_j) \in \mathcal{E}_s$  表示资源  $r_i$  与  $r_j$  之间存在逻辑关联。

将学习者  $u$  抽象为超边  $e \in \mathcal{E}$ , 其交互的多个学习资源  $\mathcal{R}$  作为超边连接的节点, 构建超图结构  $G = (\mathcal{R}, \mathcal{E})$ 。历史学习交互序列长度  $S$  基于时间戳被拆分成  $T$  个子集, 以构造顺序超图  $G = \{G^t = (\mathcal{R}^t, \mathcal{E}^t) \mid t = 1, 2, \dots, T\}$ , 其中  $\mathcal{R}^t$  是学习资源集合。

个性化学习路径推荐目标可表述为: 给定学习者在时间戳  $t$  之前与学习资源的历史交互  $\mathcal{H}$ , 基于学习资源之间的依赖关系和学习者学习行为偏好, 找到在  $t+1$  时学习者最有可能选择作为下一个学习任务的学习资源。传统方法多聚焦于单一目标优化(如点击率最大化), 而本文进一步引入多目标优化过程, 生成覆盖学习者偏好、学习资源匹配度、认知增益与多样性的学习路径序列  $\mathcal{L} = \{r_{t+1}, r_{t+2}, \dots, r_{t+k}\}$ 。

模型整体架构如图 1 所示, 包含 3 个组成部分。第一部分是超图-图学习路径生成模块, 通过 GCN 获取初始的学习资源嵌入, 并通过顺序超图获取基于交互的学习资源和学习者偏好嵌入, 结合双通道 GRU 和 Transformer 模块获取学习者历史交互序列的长短期特征, 最后根据 MLP 输出的推荐概率生成初始学习路径; 第二部分是动态知识追踪模块, 使用 LSTM 对融合邻居信息的学习资源嵌入与学习者答题记录以及题目难度信息进行动态编码, 预测学习者对知识的掌握状态; 第三部分是多目标优化模块, 使用 NSGA-II 对学习路径进行多目标优化, 并从 Pareto 前沿解集中计算综合效用函数, 得到最终学习路径。

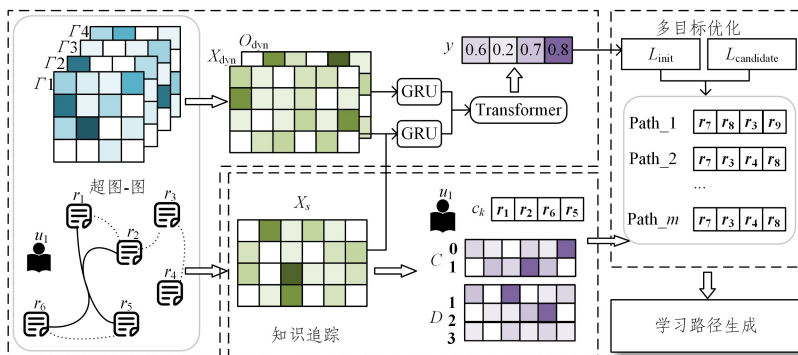


图 1 超图神经网络与动态知识追踪融合的学习路径推荐模型架构(电子版为彩图)

Fig. 1 Framework of learning path recommendation model integrating hypergraph neural networks and dynamic knowledge tracking

### 3.2 超图-图混合表征学习者历史交互

#### 3.2.1 静态学习资源建模

使用 GCN 捕捉学习资源之间的静态逻辑关系,获取学习资源的嵌入表示。

通过 GCN 的消息传递机制,每个节点(学习资源)的嵌入向量  $\mathbf{x}_j \in \mathbb{R}^d$  基于其邻居节点特征迭代更新,生成包含全局依赖关系的学习资源嵌入表示,  $d$  表示嵌入向量的维度。基于学习资源依赖关系构建邻接矩阵  $\mathbf{A}_s \in \mathbb{R}^{N \times N}$ ,采用图卷积网络编码学习资源关系传播,如式(1)所示:

$$\mathbf{X}_s^{(l+1)} = \phi(\tilde{\mathbf{D}}_s^{-\frac{1}{2}}(\mathbf{A}_s + \mathbf{I})\tilde{\mathbf{D}}_s^{-\frac{1}{2}}\mathbf{X}_s^{(l)}\mathbf{W}_s^{(l)}) \quad (1)$$

其中,  $\mathbf{X}_s^{(l)} \in \mathbb{R}^{N \times d}$  为第  $l$  层节点特征矩阵;  $N$  为学习资源总数;学习资源初始嵌入为  $\mathbf{X}_s^{(0)} \in \mathbb{R}^{N \times d}$ ,根据正态分布随机初始化;  $\phi$  为激活函数 ReLU;  $\tilde{\mathbf{D}}_s$  为带自环的度矩阵;  $\mathbf{W}_s^{(l)} \in \mathbb{R}^{d \times d}$  为可训练参数。

#### 3.2.2 动态学习者行为偏好建模

通过超图卷积网络(HyperGraph Convolutional Network, HGCN)学习高阶交互关系,利用记忆增强的顺序超图网络,动态捕捉学习者与学习资源之间的复杂依赖关系,生成动态学习资源嵌入,捕捉学习者偏好。

由于学习者历史行为能够准确反映其偏好,因此可以利用学习者与学习资源的历史交互构建超图。将时间轴划分为  $T$  个等长区间  $\{\mathcal{T}_1, \mathcal{T}_2, \dots, \mathcal{T}_T\}$ ,其中  $\mathcal{T}_t = [\tau_{t-1}, \tau_t)$ ,  $\Delta\tau = \tau_t - \tau_{t-1}$  为固定窗口大小。对每个时间窗口  $\mathcal{T}_t$ ,构建超图  $\mathcal{G} = (\mathbf{R}^t, \mathcal{T}^t)$ ,  $t = \{1, 2, \dots, T\}$ 。其中:  $\mathbf{R}^t = \{r_j | (u_i, r_j, t_k) \in \mathcal{H}, t_k \in \mathcal{T}_t\}$  为节点集合,  $\mathcal{E}^t = \{e_i^t | u_i \in \mathcal{U}\}$  为超边集合。超边  $e_i^t$  连接学习者  $u_i$  在  $\mathcal{T}_t$  内交互的所有学习资源,即  $e_i^t = \{r_j | (u_i, r_j, t_k) \in \mathcal{H} \wedge t_k \in \mathcal{T}_t\}$ 。每个超边  $e_i^t$  对应一个学习者  $u_i$  在特定时间窗口内的完整学习轨迹。

超图关联矩阵  $\mathbf{H} \in \{0, 1\}^{|\mathcal{R}| \times |\mathcal{U}|}$  如式(2)所示:

$$H(r_j, e_i) = \begin{cases} 1, & \text{若资源 } r_j \text{ 属于超边 } e_i \\ 0, & \text{否则} \end{cases} \quad (2)$$

节点到超边的聚合过程中,超边  $e_i$  的特征  $o_i$  由其关联节点  $r_j$  的嵌入表示  $x_j$  加权聚合,如式(3)所示:

$$\mathbf{o}_i^{(l+1)} = \phi(\sum_{r_j \in \mathcal{N}(e_i)} \mathbf{W}_1^{(l)} \mathbf{x}_j^{(l)}) \quad (3)$$

其中,  $\phi$  为激活函数 ReLU;  $\mathbf{W}_1^{(l)} \in \mathbb{R}^{d \times d}$  为  $l$  层的可训练的权重矩阵;  $d$  是嵌入的维数;  $\mathcal{N}(e_i) = \{r_j | H(r_j, e_i) = 1\}$  表示超边  $e_i$  连接的节点集合。

超边到节点的聚合过程中,节点  $r_j$  的特征  $x_j$  更新为关联超边  $e_i$  特征  $o_i$  的加权和,如式(4)所示:

$$\mathbf{x}_j^{(l+1)} = \phi(\sum_{e_i \in \mathcal{E}(r_j)} \mathbf{W}_2^{(l)} \mathbf{o}_i^{(l+1)}) \quad (4)$$

其中,  $\phi$  为激活函数 ReLU;  $\mathbf{W}_2^{(l)} \in \mathbb{R}^{d \times d}$  为  $l$  层的可训练的权重矩阵;  $d$  是嵌入的维数;  $\mathcal{E}(r_j) = \{e_i | H(r_j, e_i) = 1\}$  表示包含节点  $r_j$  的超边集合。

$\mathcal{M} = \{(\tau_t, \mathbf{X}_t, \mathbf{O}_t)\}_{t=1}^T$  表示各个时间顺序超图生成的资源嵌入,  $\mathbf{X}_t \in \mathbb{R}^{N \times d}$  为资源嵌入,  $\mathbf{O}_t \in \mathbb{R}^{M \times d}$  为超边(学习者)嵌入。  $\mathbf{x}_{j,t_k}^{\text{dyn}} = \mathbf{X}_t[j]$ ,  $t = \max\{s | \tau_s \leq t_k\}$  表示资源  $r_j$  在时间  $t_k$  的嵌入。

将静态学习资源关系图学习到的嵌入与超图学习到的表示进行融合,如式(5)所示:

$$\begin{cases} \mathbf{x}^{\text{fu}} = g\mathbf{x}_{j,t_k}^s + (1-g)\mathbf{x}_{j,t_k}^{\text{dyn}} \\ g = \sigma(\mathbf{w}_g^T [\phi(\mathbf{W}_a \mathbf{x}^s); \phi(\mathbf{W}_b \mathbf{x}^{\text{dyn}})]) \end{cases} \quad (5)$$

其中,  $\phi$  为 ReLU 激活函数;  $\mathbf{x}_{j,t_k}^s$  表示由 GCN 从静态图中学习得到的  $r_j$  的特征向量;  $\mathbf{x}_{j,t_k}^{\text{dyn}}$  表示由 HGCN 从动态超图中学习得到的  $r_j$  的特征向量;  $\mathbf{W}_a$  和  $\mathbf{W}_b$  为特征变换矩阵;  $\mathbf{w}_g$  为门控权重向量;  $\sigma$  为 sigmoid 激活函数。

#### 3.2.3 初始路径生成

历史交互行为建模完成后生成初始路径,即对学生学习过程中的动态演进进行建模,以生成初始推荐列表。具体做法是:引入门控循环单元(GRU)和 Transformer 模块,用于捕捉学习序列的长期演进特征,并重建输入交互矩阵,以预测缺失的交互。双通路 GRU 单元将超图-图模块生成的动态学习资源嵌入  $\mathbf{X}^{\text{fu}}$  与学习者行为序列特征  $\mathbf{O}_t$  进行长期时序建模,合并状态获得学习者行为序列隐藏状态,如式(6)所示:

$$\mathbf{h}_t = \text{GRU}(\mathbf{x}_t^{\text{fu}}, \mathbf{h}_{t-1}) + \text{GRU}(\mathbf{o}_t, \mathbf{h}_{t-1}) \quad (6)$$

根据隐藏状态序列,采用基于 Transformer 的自注意力编码器重建输入交互矩阵,增强对学习进度演进的捕捉能力。该模块由多个相同的编码层堆叠而成,每层包含多头自注意力机制和位置感知前馈神经网络两个子模块,分别用于捕捉序列元素间的全局依赖和特征变换。得到更新后的学习者的嵌入  $\mathbf{Z}$ ,如式(7)所示:

$$\mathbf{Z} = \mathbf{H}^{(L)} = \text{TransformerEncoder}(\mathbf{H}^{(0)}) \quad (7)$$

通过全连接层计算每个学习资源  $r_j$  未归一化的推荐得分,如式(8)所示:

$$\mathbf{P} = \mathbf{Z}\mathbf{W}_{p1} + \mathbf{b}_{p1} + \mathbf{M} \quad (8)$$

其中,  $\mathbf{W}_{p1} \in \mathbb{R}^{d \times N}$  为权重矩阵;  $d$  为嵌入维数;  $\mathbf{b}_{p1} \in \mathbb{R}^N$  为偏置项;  $\mathbf{M}$  为历史行为掩码,用于在推荐过程中过滤学习者已经学过的学习资源。掩码对已出现学习资源的位置标记为  $-\infty$ ,如式(9)所示:

$$\mathbf{M}_{i,j,t} = \begin{cases} 0, & \text{若 } u_i \text{ 在 } t \text{ 前未学习 } r_j \\ -\infty, & \text{否则} \end{cases} \quad (9)$$

通过 softmax 函数归一化推荐概率,按概率排序生成初始推荐列表  $\mathcal{L}_{\text{ini}}$ ,如式(10)所示:

$$\hat{\mathbf{y}} = \text{softmax}(\mathbf{P}) \quad (10)$$

推荐任务使用交叉熵损失函数计算损失,如式(11)所示:

$$\mathcal{L} = - \sum_{i=2}^{|\mathcal{H}|} \sum_{j=1}^{|\mathcal{R}|} y_{i,j} \log \hat{y}_{i,j} \quad (11)$$

其中,  $y_{i,j} \in \{0, 1\}$  表示真实标签。如果用户在第  $i$  时间步学习了资源  $r_j$ ,则  $y_{i,j} = 1$ ; 否则  $y_{i,j} = 0$ 。

### 3.3 图增强型动态知识追踪机制

通过知识追踪模块,分析学习者的知识掌握状态,量化学习者的知识增益潜力。

输入包括习题与做题结果的学习者历史行为数据,及 GCN 生成的学习资源嵌入  $\mathbf{X}_s$ ,构建知识状态向量,如式(12)所示:

$$\mathbf{s}_t = \text{LSTM}(\mathbf{x}_t, \|\mathbf{c}_k\| \|\mathbf{d}_j, \mathbf{s}_{t-1}) \quad (12)$$

其中,  $\mathbf{c}_k$  为答题情况,0 为错误,1 为正确;  $\mathbf{d}_j \in \{1, 2, 3\}$  为学习资源  $r_j$  的难度。

根据学习者知识状态预测其答题正确的概率,如式(13)所示:

$$p_{t+1} = \sigma(\mathbf{s}_t \mathbf{W}_{p_2} + \mathbf{b}_{p_2}) \quad (13)$$

其中,  $\sigma$  为 Sigmoid 函数,  $\mathbf{W}_{p_2}$  为可学习参数,  $\mathbf{b}_{p_2}$  为偏置项。

知识状态预测损失使用二元交叉熵损失(Binary Cross-Entropy Loss)计算, 如式(14)所示:

$$\mathcal{L}_t = -[y \log p + (1-y) \log(1-p)] \quad (14)$$

其中,  $y$  为真实标签。

根据预测结果识别薄弱知识点, 并量化知识增益  $Gain_j$ , 如式(15)所示:

$$Gain_j = \frac{p(r_j^{\text{after}}) - p(r_j^{\text{before}})}{1 - p(r_j^{\text{before}})} \quad (15)$$

其中,  $p(r_j^{\text{after}})$  为学生完成学习路径之后学习资源  $r_j$  的正确概率,  $p(r_j^{\text{before}})$  为学生完成学习路径之前学习资源  $r_j$  的正确概率。通过调整分母, 确保不同初始水平学生的增益可比。

### 3.4 多目标优化驱动的个性化路径生成

通过交叉、替换操作在  $\mathcal{L}_{\text{init}}$  上扩展候选路径, 生成多样化候选学习路径集合  $C = \{\mathcal{L}_1, \mathcal{L}_2, \dots, \mathcal{L}_n\}$ 。

采用非支配排序遗传算法 II(Non-dominated Sorting Genetic Algorithm II, NSGA-II)进行多目标优化, 通过 Pareto 优化路径选择。

所述多目标优化问题模型如式(16)所示:

$$\begin{cases} \text{设 } \mathcal{L} = [r_1, r_2, \dots, r_k]^T \\ \max f_1(\mathcal{L}), f_2(\mathcal{L}), f_3(\mathcal{L}), f_4(\mathcal{L}), \mathcal{L} \in C \\ \text{s. t. } \begin{cases} p(r_i^{\text{before}}) < 0.9 \\ r_i \neq r_j, r_i, r_j \in \mathcal{L} \end{cases} \end{cases} \quad (16)$$

由于生成的初始学习路径依据学习者喜好进行推荐, 因此根据输出的未归一化推荐得分  $P$  生成学习资源喜好概率, 如式(17)所示:

$$p_{\text{prefer}} = \text{Sigmoid}(p) \quad (17)$$

学习者偏好的目标函数如式(18)所示:

$$f_1(\mathcal{L}) = \text{Preference}(\mathcal{L}) = \frac{\sum_{i=1}^M (p_{\text{prefer}, i})}{|M|} \quad (18)$$

其中,  $|M|$  为表示列表的长度。

适应性的目标函数如式(19)所示:

$$\begin{cases} f_2(\mathcal{L}) = \text{Adaptivity}(\mathcal{L}) = \frac{\sum_{i=1}^M (1 - |\delta_i - D_i f_i|)}{|M|} \\ \delta_i = \frac{\sum_{i=t-T}^t D_i f_i \cdot c_i}{\sum_{i=t-T}^t c_i + \epsilon} \end{cases} \quad (19)$$

其中,  $\delta_i$  为学生当前的能力值;  $T$  为历史窗口大小(如最近 5 次答题);  $\epsilon$  为平滑项(防止分母为 0, 默认  $\epsilon = 1 \times 10^{-5}$ );  $D_i f_i$  为第  $i$  个学习资源的标注难度。

有效性的目标函数<sup>[34]</sup>如式(20)所示:

$$\begin{aligned} f_3(\mathcal{L}) = E_p(\mathcal{L}) &= \frac{E_e - E_s}{E_{\text{sup}} - E_s} \\ &= \frac{1}{|M|} \sum_{i=1}^M \frac{p(r_i^{\text{after}}) - p(r_i^{\text{before}})}{1 - p(r_i^{\text{before}})} \\ &= \frac{1}{|M|} \sum_{i=1}^M Gain_i \end{aligned} \quad (20)$$

其中,  $E_e$  为在学习路径  $\mathcal{L}$  之后学生对目标资源的掌握;  $E_s$  为在

学习路径之前学生对目标资源的掌握;  $E_{\text{sup}}$  为对目标资源掌握的上限;  $Gain_i$  为知识增益。

多样性的目标函数如式(21)所示:

$$f_4(\mathcal{L}) = \text{Diversity}(\mathcal{L}) = \frac{2 \sum_{r_i \in \mathcal{L}, r_j \in \mathcal{L}} (1 - \text{sim}(\mathbf{x}_i, \mathbf{x}_j))}{|M| |M-1|} \quad (21)$$

其中,  $r_i$  和  $r_j$  为路径  $\mathcal{L}$  中第  $i$  个和第  $j$  个学习资源;  $\mathbf{x}_i$  和  $\mathbf{x}_j$  为学习资源  $r_i$  和  $r_j$  的嵌入向量;  $\text{sim}$  为余弦相似度。

基于拥挤度和非支配解, 确定帕累托前沿解集  $\mathcal{P} = \{\mathcal{L}_1, \mathcal{L}_2, \dots, \mathcal{L}_m\}$ ,  $m$  为前沿解集个数。

动态分配各目标权重, 确定综合效用函数, 通过计算函数值输出最终推荐路径作为最优学习路径  $\mathcal{L}_{\text{final}}$ 。所述综合效用函数如式(22)所示:

$$S(\mathcal{L}) = \lambda_1 \cdot \text{Preference}(\mathcal{L}) + \lambda_2 \cdot \text{Adaptivity}(\mathcal{L}) + \lambda_3 \cdot E_p(\mathcal{L}) + \lambda_4 \cdot \text{Diversity}(\mathcal{L}) \quad (22)$$

其中,  $\lambda_1$  为偏好目标函数对应的权重,  $\lambda_2$  为适应性目标函数对应的权重,  $\lambda_3$  为有效性目标函数对应的权重,  $\lambda_4$  为多样性目标函数对应的权重。

### 3.5 复杂度计算

对模型各主要模块的复杂度进行系统分析, 分别给出静态图卷积网络、动态超图卷积网络、双通道 GRU、Transformer 编码器及多目标优化算法的复杂度表达式, 并量化说明关键参数的影响。对于静态图卷积网络, 时间复杂度为  $O(L_s \times (|\mathcal{E}_s| \times d + |\mathcal{R}| \times d^2))$ , 其中  $L_s$  为 GCN 层数,  $|\mathcal{E}_s|$  为资源间逻辑依赖的边数,  $|\mathcal{R}|$  为学习资源数量,  $d$  为嵌入维度; 对于动态超图卷积网络, 时间复杂度为  $O(T \times L_h \times (|\mathcal{H}| \times d + |\mathcal{E}| \times d^2))$ , 其中  $T$  为时间窗口数,  $L_h$  为超图卷积层数,  $|\mathcal{H}|$  为历史交互记录数,  $|\mathcal{E}|$  为超边数(学习者数量); 对于双通道 GRU, 时间复杂度为  $O(\tau \times d^2)$ , 其中  $\tau$  为序列长度; 对于 Transformer 编码器, 时间复杂度为  $O(L_t \times (\tau^2 \times d + \tau \times d^2))$ , 其中  $L_t$  为 Transformer 层数; 对于多目标优化, 时间复杂度为  $O(G \times M \times P^2)$ , 其中  $G$  为迭代次数,  $M$  为目标函数数量,  $P$  为种群大小。

## 4 实验验证

### 4.1 实验设置

#### 4.1.1 数据集

实验部分从 MOOCube 数据集分层采样了 10000 个学生与课程视频的历史交互记录, 并从 MOOPer 数据集采样了 5000 个学生的历史答题记录进行分析。

MOOCube<sup>[35]</sup>: 面向大规模在线教育有关的自然语言处理、知识图谱、数据挖掘等研究者的开放数据仓库, 包含 199199 名学习者的课程交互记录, 包括 706 门真实在线课程、38181 个教学视频。

MOOPer<sup>[36]</sup>: 信息技术类专业大规模在线实践教学平台 EduCoder 发布的公开数据集, 主要分为交互数据与知识图谱。其包含 2532524 条实践练习数据, 可提取学习者与练习的历史交互数据, 包括练习结果、练习时间及难度等。

#### 4.1.2 参数设置

图卷积网络层数为 3, 超图时序列划分个数为 4, 超图神经

网络层数为2,嵌入维度  $d$  为64。Tranformer层数为1,注意力头数为2。优化器采用Adam,训练轮次=60。推荐路径学习资源个数  $K=6$ ,候选学习资源个数  $C=14$ 。历史窗口  $T=5$ 。综合效用函数采用的参数如表1所列。

表1 学习阶段的参数设置

Table 1 Parameter settings for the learning stage

| 学习阶段   | $\lambda_1$ | $\lambda_2$ | $\lambda_3$ | $\lambda_4$ |
|--------|-------------|-------------|-------------|-------------|
| 初期(薄弱) | 0.5         | 0.3         | 0.1         | 0.1         |
| 中期(巩固) | 0.3         | 0.4         | 0.2         | 0.1         |
| 后期(提升) | 0.2         | 0.3         | 0.4         | 0.1         |

## 4.2 初始路径生成

### 4.2.1 评估指标

学习路径推荐的评估指标主要有  $HR@K$ ,  $MRR@K$  和  $NDCG@K$ 。命中率(Hit Ratio)的表征参数为  $HR@K$ ,表示推荐路径中正确学习资源出现在前  $Top-k$  推荐结果的比例,是衡量推荐系统覆盖能力的重要指标。 $HR@K$  的定义如式(23)所示:

$$HR@K = \frac{\sum_{u=1}^{|\mathcal{U}|} Hit_u@K}{\sum_{u=1}^{|\mathcal{U}|} |\mathcal{R}_u|} \quad (23)$$

其中,  $Hit_u@K$  表示前  $K$  推荐列表中用户  $u$  实际交互的学习资源数量,  $|\mathcal{U}|$  是测试数据集集中的学生数量,  $|\mathcal{R}_u|$  是学生  $u$  真实学习过的学习资源数量。

排名的倒数(Mean Reciprocal Ranking, MRR)用于评估排序列表中第一个相关结果出现的位置,表征参数为  $MRR@K$ 。 $MRR@K$  的定义如式(24)所示:

$$MRR@K = \frac{1}{|\mathcal{N}|} \sum_{i=1}^{|\mathcal{N}|} \frac{1}{rank_i} \quad (24)$$

其中,  $rank_i$  表示正确预测学习资源在  $Top-k$  中的排列位置。

归一化折损累积增益(Normalized Discounted Cumulative Gain)的表征参数为  $NDCG@K$ ,其定义如式(25)所示:

$$NDCG@K = \frac{1}{|\mathcal{U}|} \sum_{u=1}^{|\mathcal{U}|} \frac{DCG_u@K}{IDCG_u@K} \quad (25)$$

其中,  $DCG_u@K$  为折损累积增益(DCG),  $IDCG_u@K$  是学生  $u$  的理想 DCG。 $DCG_u@K$  定义如式(26)所示:

$$DCG_u@K = \sum_{k=1}^K \frac{2^{rel_{u,k}} - 1}{\log_2(k+1)} \quad (26)$$

其中,  $rel_{u,k}$  为学生  $u$  在排名列表中位置  $k$  处的学习资源的相关性得分。如果第  $k$  个学习资源是相关的,则  $rel_{u,k}=1$ ; 否则为0。 $IDCG_u@K$  的定义如式(27)所示:

$$IDCG_u@K = \sum_{k=1}^{|\mathcal{REL}|_K} \frac{2^{rel_{u,k}} - 1}{\log_2(k+1)} \quad (27)$$

其中,  $|\mathcal{REL}|_K$  表示在最佳条件下按照分级相关性值的顺序对学生  $u$  的前  $k$  个推荐学习资源进行排序。

### 4.2.2 数据处理与实验设置

在模型构建阶段,基于 MOOCube 数据集开展学习资源关系建模的关键性预实验。首先对原始数据进行多维度清洗:1)过滤学习行为记录少于5次的用户;2)移除标注信息不全的学习资源;3)移除同一学习者历史交互中重复的学习资源。

针对静态学习资源关系图的构建,设计对比实验来验证两种典型关联关系的表征能力:1)基于课程隶属关系的共现连接;2)依据教学大纲设计的时序依赖关系。通过分层抽样选取前1000位活跃用户的学习轨迹数据,按8:1:1的比例划分训练集、验证集与测试集,实验结果如表2及表3所列。由表中数据可知,采用时序依赖关系的模型在推荐任务覆盖能力( $HR@5=0.694$ )和排序质量( $NDCG@5=0.645$ )上均优于课程共现关系( $HR@5=0.289$ ,  $NDCG@5=0.208$ )。这表明,相较于课程隶属关系,学习资源间的时间依赖性更能反映知识体系的逻辑演进规律,为后续学习资源静态关系图的构建提供了实证依据。

表2 学习资源不同关系构建静态图的命中率对比

Table 2 Comparison of the hit ratio of static graphs constructed by different relationships of learning resources

| 学习资源关系 | $HR@5$ | $HR@10$ | $HR@15$ |
|--------|--------|---------|---------|
| 课程隶属关系 | 0.289  | 0.371   | 0.424   |
| 时序依赖关系 | 0.694  | 0.709   | 0.713   |

表3 学习资源不同关系构建静态图的 NDCG 对比

Table 3 NDCG comparison of static graphs constructed by different relationships of learning resources

|        | $NDCG@5$ | $NDCG@10$ | $NDCG@15$ |
|--------|----------|-----------|-----------|
| 课程隶属关系 | 0.208    | 0.234     | 0.248     |
| 时序依赖关系 | 0.645    | 0.650     | 0.651     |

### 4.2.3 初始路径生成

初始学习路径推荐指标如表4及表5所列。在路径质量评估中,基于 MOOCube 数据集进行视频学习资源推荐,  $Top-20$  的命中率达到90.6%;基于 MOOPer 数据集进行习题学习资源推荐,  $Top-20$  的命中率达到95.3%。同时,两者 MRR 指标均具有排名稳定性,说明通过 HGCN 构建表征能够更完整地保留学习路径中的时序依赖与学习资源关联特征,为捕捉核心依赖关系与学习路径精准推荐提供了潜在条件。

表4  $Top-k$  路径推荐的 HR 指标Table 4 HR metric for  $Top-k$  path recommendation

|         | $HR@5$ | $HR@10$ | $HR@20$ |
|---------|--------|---------|---------|
| MOOCube | 0.804  | 0.867   | 0.906   |
| MOOPer  | 0.939  | 0.947   | 0.953   |

表5  $Top-k$  路径推荐的 MRR 指标Table 5 MRR metric for  $Top-k$  path recommendation

|         | $MRR@5$ | $MRR@10$ | $MRR@20$ |
|---------|---------|----------|----------|
| MOOCube | 0.673   | 0.681    | 0.684    |
| MOOPer  | 0.907   | 0.908    | 0.909    |

### 4.2.4 与其他方法的对比

为了更加准确、全面地衡量模型生成高质量、有序的学习路径推荐列表的能力,将所提学习路径生成模型与 LSMFERLI, KGCN-LV, HINSC 等6种前沿推荐方法(见表6)在 MOOCube 数据集上进行了对比评估,评估采用体现覆盖能力的  $HR@K$ (命中率)与体现排序质量  $NDCG@K$ (归一化折损累积增益)指标( $K=5,10,15$ )。上述指标的组

合能够更好地横向对比不同方法在学习路径推荐任务的综合表现。实验结果如表 6 所列。

表 6 与其他模型的指标对比

Table 6 Comparison of other model's indicators

| Methods  | HR@5  | NDCG@5 | HR@10 | NDCG@10 | HR@15 | NDCG@15 |
|----------|-------|--------|-------|---------|-------|---------|
| KGCN-LV  | 0.349 | 0.207  | 0.451 | 0.286   | 0.476 | 0.297   |
| HINSC    | 0.367 | 0.223  | 0.479 | 0.309   | 0.506 | 0.323   |
| AMHIN    | 0.382 | 0.238  | 0.495 | 0.327   | 0.541 | 0.342   |
| ACKRec   | 0.358 | 0.214  | 0.468 | 0.298   | 0.489 | 0.315   |
| ACMF     | 0.401 | 0.242  | 0.532 | 0.336   | 0.553 | 0.351   |
| LSMFERLI | 0.453 | 0.269  | 0.589 | 0.383   | 0.617 | 0.397   |
| Ours     | 0.805 | 0.706  | 0.868 | 0.727   | 0.893 | 0.733   |

LSMFERLI<sup>[37]</sup>是一种基于低秩稀疏矩阵分解(Matrix Factorization,LSMF)的MOOCs视频资源推荐系统;KGCN-LV<sup>[38]</sup>是一种集成了卷积神经网络与知识图谱用于学习资源推荐的端到端深度学习框架;HINSC<sup>[39]</sup>是一种基于学生行为数据构建加权异构信息网络并结合图卷积网络的学习资源推荐方法;AMHIN<sup>[40]</sup>基于多注意机制和异构信息网络进行学

习资源推荐;ACKRec<sup>[41]</sup>是一种基于图神经网络的端到端的学习资源推荐方法;ACMF<sup>[42]</sup>是一种基于图卷积网络和注意力机制的学习资源推荐方法。

与上述方法相比,本文所提出的学习资源推荐模型在若干指标上均呈现出不同程度的优化。其中,HR@10指标达到0.868,较6种方法中表现较优的LSMFERLI方法(0.589)提升了27.9个百分点。值得说明的是,模型在短期推荐场景(HR@5:0.805 vs 0.453)和长期推荐场景(NDCG@15:0.733 vs 0.397)中分别取得约35.2个百分点和33.6个百分点的提升。实验结果表明,采用超图-图混合结构,有助于更准确地对学习资源进行建模,并能有效捕捉学习行为的连续特征。

#### 4.2.5 消融实验结果与分析

为了验证模型中各组件对推荐性能的贡献,本文使用10%的数据设计了消融实验,对比了不同变体模型在多个评估指标上的表现。实验选取了HR@K,MRR@K和NDCG@K(K=5,10,15)作为评估指标,结果如表7所列。

表 7 消融实验

Table 7 Ablation experiment

|                 | HR@5  | NDCG@5 | HR@10 | NDCG@10 | HR@15 | NDCG@15 | MRR@5 |
|-----------------|-------|--------|-------|---------|-------|---------|-------|
| 完整模型            | 0.694 | 0.645  | 0.709 | 0.650   | 0.713 | 0.651   | 0.629 |
| w/o HGNN        | 0.681 | 0.621  | 0.697 | 0.626   | 0.704 | 0.623   | 0.600 |
| w/o transformer | 0.532 | 0.456  | 0.539 | 0.465   | 0.573 | 0.468   | 0.430 |
| w/o 双通道 GRU     | 0.527 | 0.457  | 0.463 | 0.469   | 0.578 | 0.472   | 0.437 |
| w/o GCN         | 0.503 | 0.440  | 0.529 | 0.448   | 0.543 | 0.452   | 0.419 |

1)完整模型在HR@5,NDCG@5以及MRR@5上分别达到了0.694,0.645和0.629,显著优于其他消融版本。随着推荐列表长度K的增加,完整模型的性能优势依然稳定,表明其各组件协同作用有效提升了推荐效果。

2)去掉HGNN后(w/o HGNN),模型性能全面下降,其缺失导致MRR@5和NDCG@5分别降低了2.9个百分点和2.4个百分点,验证了HGNN通过高阶关系建模在学习者行为偏好建模上的作用。

3)去掉Transformer(w/o transformer)导致HR@5和MRR@5分别降低了16.2个百分点和19.9个百分点,表明Transformer在捕捉学习者-学习资源交互的全局依赖关系上起到了关键作用。

4)去掉双通道GRU的模型(w/o 双通道GRU)导致HR@5和NDCG@5分别降低了16.7个百分点和18.8个百分点,说明时序特征的双通道建模对学习资源推荐效果至关重要,尤其是对学习者学习行为序列的动态建模。

5)GCN的消融(w/o GCN)对性能影响最大,其缺失导致HR@5和NDCG@5分别下降19.1个百分点和20.5个百分点,验证了GCN对学习资源建模的作用,其显著提升了推荐的准确性和排序质量。

### 4.3 学习状态追踪

#### 4.3.1 预测答题结果计算指标

ACC(Accuracy)是指模型正确预测的样本数占总样本数的比例,用于衡量模型整体预测的正确性。其计算式如式(28)所示:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (28)$$

其中,TP(True Positive)表示预测为正确且实际正确的样本数,TN(True Negative)表示预测为错误且实际错误的样本数,FP(False Positive)表示预测为正确但实际错误的样本数,FN(False Negative)表示预测为错误但实际正确的样本数。

AUC(Area Under the Curve)是ROC曲线(Receiver Operating Characteristic Curve)下的面积,用于衡量模型在不同分类阈值下的综合性能。ROC曲线以真正例率(TPR)为纵轴,假正例率(FPR)为横轴。AUC的值通过计算ROC曲线下面积获得,范围为[0,1]。

真正例率(True Positive Rate,TPR)及假正例率(False Positive Rate,FPR)的计算式分别如式(29)和式(30)所示:

$$TPR = \frac{TP}{TP + FN} \quad (29)$$

$$FPR = \frac{FP}{FP + TN} \quad (30)$$

#### 4.3.2 实验结果

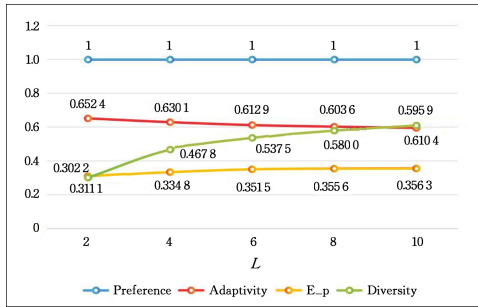
通过系统性实验验证基于超图神经网络与动态知识追踪融合的联合训练模型的性能,使用MOOPer数据集进行习题学习资源的推荐与答题结果预测。首先,在基础任务评估中,超图推荐模块在Top-5推荐命中率(HR@5)达到0.891,知识追踪模块在答题结果预测的AUC值为0.782,表明模型具备基础推荐与认知诊断能力。模型预测答题结果效果如表8所列。

表8 学习资源推荐效果与答题结果预测效果

Table 8 Effect of learning resource recommendation and the prediction effect of answer results

| HR@5  | MRR@5 | AUC   | ACC   |
|-------|-------|-------|-------|
| 0.891 | 0.814 | 0.782 | 0.854 |

图2展示了基于超图-图结构学习路径生成过程中,不同初始推荐路径长度( $L=2,4,6,8,10$ )对4项关键指标(Preference, Adaptivity, E\_p, Diversity)的影响对比。

图2  $L=2,4,6,8,10$  对关键指标的影响对比(电子版为彩图)Fig. 2 Comparison of the impact of  $L=2,4,6,8,10$  on key indicators

从趋势上看,Preference(偏好准确性)在路径长度 $L$ 增加时基本保持稳定,这主要是因为路径生成逻辑能够持续满足学习者的偏好。Adaptivity(适应性)与路径长度 $L$ 呈现一定的负相关关系,但下降趋势较为缓和,说明更长的学习路径可能导致资源与学习者能力不匹配的风险提升。E\_p(有效性)与路径长度 $L$ 呈微弱正相关,说明适度增加路径长度可能通过资源间的互补性和递进性提升学习效果。Diversity(多样

性)则随路径长度 $L$ 增加显著上升,从 $L=2$ 的0.3增至 $L=10$ 的0.6,表明长学习路径有助于覆盖更广泛的节点组合,增强了系统探索能力。如果希望在适应性与偏好之间取得平衡,将路径长度设置为 $L=6$ 较为合适;若需更强调高有效性与多样性时,可以将路径长度设置为 $L \geq 8$ ,但需相应地放宽对适应性的要求。基于上述考虑,后续实验皆采用 $L=6$ 作为推荐的路径长度设置。

#### 4.4 多目标优化

在学习路径生成策略方面,本文进一步优化了推荐流程。首先,根据超图神经网络模型生成初始学习路径,并在此基础上进一步引入多目标优化过程,基于初始推荐序列进行交叉、替换等操作,生成多条候选路径。本文提出两种候选学习资源生成策略。1)随机候选策略:从全体资源库中随机抽取 $C$ 个的候选资源,打破排序依赖,以增强多样性。2)概率筛选策略:基于推荐概率排序筛选除Top-K外的 $C$ 个次优候选资源,保留高相关性,以平衡准确性与探索性。为了进一步减小对Preference(偏好准确性)指标的影响,对路径前30%的学习资源仅以较低的概率进行替换。通过设计四维评估体系对多条路径进行多目标优化,得到前沿解集,最终根据综合效用函数获取分数最高的路径。对于不同目标的学习者,可根据各目标的不同重要程度,调节综合效用函数中的目标函数的权重参数,从而根据Pareto前沿为不同目标策略的学习者生成相应的最终学习路径。考虑不同候选策略、不同优化目标个数以及调节综合效用函数中各指标的权重参数所得到的各项指标如表9所列。

表9 学生实际学习路径与初始推荐路径及优化路径指标的对比

Table 9 Comparison of the actual learning path of students with the initial recommended path and the optimized path indicators

|        |   | Preference | Adaptivity | E_p   | Diversity |
|--------|---|------------|------------|-------|-----------|
|        | 学生实际学习路径  | —          | 0.599      | 0.331 | 0.470     |
|        | 初始推荐路径(优化前)   | 1.000      | 0.612      | 0.351 | 0.537     |
|        | $\lambda_1(0.5), \lambda_2(0.3), \lambda_3(0.2)$                      | 0.774      | 0.643      | 0.395 | —         |
| 随机候选策略 | 初期参数 $\lambda_1(0.5), \lambda_2(0.3), \lambda_3(0.1), \lambda_4(0.1)$ | 0.787      | 0.647      | 0.341 | 0.791     |
|        | 中期参数 $\lambda_1(0.3), \lambda_2(0.4), \lambda_3(0.2), \lambda_4(0.1)$ | 0.663      | 0.734      | 0.445 | 0.820     |
|        | 后期参数 $\lambda_1(0.2), \lambda_2(0.3), \lambda_3(0.4), \lambda_4(0.1)$ | 0.566      | 0.682      | 0.583 | 0.836     |
| 概率筛选策略 | 初期参数 $\lambda_1(0.5), \lambda_2(0.3), \lambda_3(0.1), \lambda_4(0.1)$ | 0.999      | 0.790      | 0.460 | 0.679     |
|        | 中期参数 $\lambda_1(0.3), \lambda_2(0.4), \lambda_3(0.2), \lambda_4(0.1)$ | 0.999      | 0.780      | 0.495 | 0.667     |
|        | 后期参数 $\lambda_1(0.2), \lambda_2(0.3), \lambda_3(0.4), \lambda_4(0.1)$ | 0.998      | 0.705      | 0.584 | 0.663     |

根据随机候选策略生成候选路径,考虑优化Preference, Adaptivity, E\_p目标时,将参数设置为 $\lambda_1=0.5, \lambda_2=0.3, \lambda_3=0.2$ ,结果显示,在准确率保持较高水平的基础上,有效性(E\_p)和适应性(Adaptivity)都有一定提升。考虑优化Preference, Adaptivity, E\_p及Diversity目标时,参数设定须契合不同学习阶段的特性。学习初期,鉴于学习者知识基础薄弱,偏好参数设为0.5,(难度)适应性参数设为0.3,以推荐贴合偏好且难度适配的路径;同时,因初期对知识增益要求低,有效性参数设为0.1;为避免路径偏离偏好,多样性参数皆设为0.1。学习中期,学习者须巩固知识,(难度)适应性参数提升至0.4,有效性参数增至0.2,偏好参数则降至0.3。学习后期,聚焦学习效果提升,有效性参数提升为0.4,(难度)适应性参数设为0.3,偏好参数降至0.2,以助力拓展知识领域。

实验结果显示,初期参数设置偏向于初学者,推荐的学习

资源则更加符合其偏好,偏好参数 $\lambda_1$ 最大,因此偏好指标的值相较于其他两个阶段更高。基于中期参数的学习资源推荐,旨在引导学习者在其偏好领域内获得难度适配的学习资源,(难度)适应性参数 $\lambda_2$ 最大(0.4),因此偏好指标介于其他两个阶段之间,而适应性指标较其他两者更高。后期参数推荐的学习资源偏向于促进学习者学习效果的提升,有效性参数 $\lambda_3$ 最大(0.4),因此有效性指标的值为三者中最高。实验表明,基于帕累托最优策略的多目标优化模型可有效实现各指标之间的平衡。例如,在中期权重参数设置条件下学习偏好契合度达到65%以上,与单目标优化方法相比,路径适应性提升了19.9%,学习增益有效性增加26.7%,同时学习资源多样性指标也有52.7%的显著优化。

相比之下,概率筛选策略生成的候选资源在维持与学习者偏好高度契合的前提下,显著提升了路径的适应性(Adap-

tivity)、有效性(E\_p)及多样性(Diversity)。相较于随机候选策略,该策略通过推荐概率的次优筛选机制,能够更精准地保障学习路径与学习者需求的匹配度,准确率达到 99.8%。相较于初始推荐路径,适应性与有效性的优化效果也更明显,平均分别提升 23.8%和 46.1%。然而,其依赖概率排序的生成逻辑对多样性指标存在边际约束。实验数据显示,其相较于初始路径多样性得分平均提升 24.5%,但较随机策略有所降低,表明二者在“质量优先”与“探索性扩展”间存在显性权衡。

#### 4.5 学习路径推荐效果

在学习路径推荐系统(LPR)的研究中,模型的有效性验证通常依赖模拟器环境下的指标对比<sup>[43-44]</sup>。本文通过对比历史数据集中学生实际学习路径与模型推荐路径的指标来验证学习路径推荐的效果。有效性指标 E\_p 反映了所推荐学习路径对学习目标掌握程度提升的整体效果。适应性指标 Adaptivity 衡量了学习路径中的学习资源难度与学习者能力的匹配程度。多样性指标 Diversity 体现了推荐资源的多样性。具体对比结果如表 9 所列。

学生实际学习路径的有效性为 0.331,初始推荐路径提升至 0.351;采用多目标优化策略后,后期参数配置下 E\_p 进一步提升至 0.583,伴随 Adaptivity 从 0.599 提升至 0.682, Diversity 提升至 0.836。可以看出,初始学习资源推荐序列以及优化后的学习路径在有效性、适应性和多样性的关键指标上均优于学生实际学习路径,表明推荐的学习路径能够更有效地提升学习者对学习目标的掌握程度,改善学习效果与学习体验。

#### 4.6 模型优化

3.5 节中已经系统分析了各模块的计算开销,为确保模型在实际教育平台中的适用性,本节通过分析复杂度,提出针对性的优化方案。超图卷积网络的时间复杂度为  $O(T \times L_n \times (|H| \times d + |E| \times d^2))$ 。实验测得,在 MOOC 数据集包含 80000 条交互记录上的单次超图卷积耗时约为 890ms。多目标优化环节中,NSGA-II 算法因需迭代评估种群个体(时间复杂度为  $O(G \times M \times P^2)$ ),成为系统主要瓶颈,单用户(学习者)路径生成平均耗时 1385ms。为支持大规模部署,本文设计两级优化策略。1)静态-动态特征分层缓存:静态资源嵌入每日离线更新,动态超图嵌入每小时增量刷新,实现数据处理效率的提升;2)在线轻量化推理:将 NSGA-II 替换为加权线性组合的综合效用函数策略,简化计算流程。优化后单用户路径生成平均耗时降至 20ms,显著增强了模型的实用性与部署适配性。

**结束语** 本文提出了一种超图神经网络与动态知识追踪融合的学习路径推荐模型,具体工作包括:1)构建超图-图混合结构,通过静态关系图刻画学习资源的语义关联,利用超边机制对学习资源与学习者之间的高阶交互关系进行建模,突破了传统图模型边类型单一的限制,并设计双通道门控循环单元捕捉学习者行为的动态演进;2)设计动态知识状态感知机制,使用长短期记忆网络精准捕捉学习者认知状态的连续变化特征,并利用学习资源关系图生成的资源表示增强知识状态感知机制,实现对知识掌握过程的细致感知;3)引入多目

标优化过程,建立覆盖学习者偏好、学习资源匹配度、认知增益与多样性的多维目标。

在学习路径推荐实验中,MOOCube 数据集的 HR@5 与 MRR@5 达到 80.4%与 67.3%;MOOPer 数据集的 HR@5 与 MRR@5 分别达 93.9%与 90.7%。在动态知识追踪实验中,模型在预测答题正确率方面取得了 AUC 为 0.78、ACC 为 0.85 的结果;在多目标优化实验中,选择概率筛选策略生成候选资源,并适当调整学习路径参数,偏好准确性达到 99.8%,相较于初始推荐路径,适应性平均提升 23.8%,有效性平均提升 46.1%,多样性平均提升 24.5%。

相较于其他基线模型,本文模型通过超图-图结构实现了多维度关系建模,在学习资源建模和捕捉学习者学习行为偏好方面具备更为有效的特征建模能力,并将推荐目标从单一准确率扩展至教育效能的多元评价维度,突破了传统单目标优化的局限性。多属性联合优化机制,为学习者提供了“个性化需求满足-认知能力适配-知识掌握提升-学习体验丰富”四位一体的自适应路径规划方案。该模型能够更好地应对学习者的多样化需求,实现学习资源与学习者复杂关联的有效建模,显著提升推荐系统的精准性,有助于改善学习者的学习效率和体验。在未来的研究中,计划将模型进一步扩展至更大规模和多维的教育数据集,用于验证其跨领域的泛化能力,并探索模型在不同教育场景中的应用效果;同时,还设计将实时学习反馈与模型深度融合,从而实现对学习状态的动态调整与即时学习路径重构。

#### 参考文献

- [1] HU F X, CHEN C Q, XIAO Y C. Research on the Mechanism and Path of Empowering Vocational Education with Artificial Intelligence [J]. Journal of Changsha Social Work College, 2024, 31(4): 91-95.
- [2] YUN Y, DAI H, ZHANG Y P, et al. State-of-the-art Survey on Personalized Learning Path Recommendation [J]. Journal of Software, 2022, 33(12): 4590-4615.
- [3] BANSAL S, BALIYAN N. A Study of Recent Recommender System Techniques [J]. International Journal of Knowledge and Systems Science, 2019, 10(2): 13-41.
- [4] HE K K. Significant Influence of Emerging Information Technology on Deepening Reformation of Education in the 21st Century [J]. Education Research, 2019, 40(3): 5-12.
- [5] XIE D F, ZHOU A Z, LI J Q. Research on the construction and application of personalized model based on learner portrait [C]//Proceedings of the 2023 China Tao Xingzhi Research Association Life Education Academic Symposium (II). Hunan Industrial Vocational and Technical College, 2024: 551-556.
- [6] ZHANG H, HUANG T, LYU Z H, et al. MOOCRC: A Highly Accurate Resource Recommendation Model for Use in MOOC Environments [J]. Mobile Networks and Applications, 2019, 24(1): 34-46.
- [7] LI B F, LI G F, XU J X, et al. A personalized recommendation framework based on MOOC system integrating deep learning and big data [J]. Computers and Electrical Engineering, 2023,

- 106;108571.
- [8] CHEN H Y. Research and Design of Personalized Learning Recommendation Model Based on User Learning Feature Collaborative Filtering Algorithm[J]. Journal of Guangdong Polytechnic University,2022,21(5):7-11.
- [9] GAO J Q, LIU Q H, HUANG W B. Research on Automatic Generation of Learning Paths Based on Knowledge Graph[J]. Modern Educational Technology,2021,31(7):88-96.
- [10] ALJOHANI T I, CRISTEA A I. Predicting Learners' Demographics Characteristics Deep Learning Ensemble Architecture for Learners' Characteristics Prediction in MOOCs[C]// Proceedings of the 4th International Conference on Information and Education Innovations(ICIEI 2019). Department of Computer Science Durham University,2019:24-28.
- [11] FAN Y X, DU J H, ZHANG J, et al. Adaptive Learning Path Recommendation Model for Dynamic Learning Environments [J]. e-Education Research,2024,45(6):89-96,105.
- [12] ZHOU Y T, CHU H, ZHU F F, et al. Survey on Deep Learning-based Personalized Learning Resource Recommendation [J]. Computer Science,2024,51(10):17-32.
- [13] SHEN X L, WANG J H. User Interest Recommendation Based on Knowledge Graph[J]. Computer Systems & Applications, 2025,34(4):155-165.
- [14] WANG X, WANG D X, XU C R, et al. Explainable Reasoning over Knowledge Graphs for Recommendation[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2019.
- [15] XIA X N, QI W X. Learning Behavior Interest Propagation Strategy of MOOCs Based on Multi Entity Knowledge Graph [J]. Education and Information Technologies, 2023, 28(10): 13349-13377.
- [16] CHEN P Y, FANG M Y, HOU X B, et al. Root Cause Analysis Based on Association Mining Between Accident Report and Indicator [J]. Computer Systems & Applications, 2025, 34(2): 272-280.
- [17] WANG X H, MA W Y, GUO L, et al. HGNN: Hyperedge-based graph neural network for MOOC Course Recommendation[J]. Information Processing and Management, 2022, 59(3): 102938.
- [18] ZHANG X M, LIU S, WANG H Y. Personalized learning path recommendation for e-learning based on knowledge graph and graph convolutional network[J]. International Journal of Software Engineering and Knowledge Engineering, 2023, 33(1): 109-131.
- [19] CAO Z. Research on Online Learning Resource Recommendation Method Based on Deep Learning[J]. Information Recording Materials,2024,25(11):62-64.
- [20] ZHANG Q, LI Y, ZHANG G Q, et al. A recurrent neural network-based recommender system framework and prototype for sequential E-learning[C]// 15th Symposium of Intelligent Systems and Knowledge Engineering(ISKE) held jointly with 14th International FLINS Conference(FLINS). 2020:488-495.
- [21] ZHOU Y W, HUANG C Q, HU Q T, et al. Personalized learning full-path recommendation model based on LSTM neural networks[J]. Information Sciences,2018,444:135-152.
- [22] ZHOU Y T, LI Q S, CHU H, et al. Knowledge Point Recommendation Method Based on Static and Dynamic Learning Demand Perception[J]. Journal of Software, 2024, 35(9): 4425-4447.
- [23] ZHU H P, WANG Z Y, ZHAO C C, et al. Learning Resource Recommendation Method Based on Spatiotemporal Multi-granularity Interest Modeling [J]. Journal of Computer Research and Development, 2025, 62(8): 1884-1901.
- [24] SUN L, RAO Y, ZHANG X B, et al. MS-HGAT: Memory-Enhanced Sequential Hypergraph Attention Network for Information Diffusion Prediction[C]// 36th AAAI Conference on Artificial Intelligence/34th Conference on Innovative Applications of Artificial Intelligence/12th Symposium on Educational Advances in Artificial Intelligence. 2022:4156-4164.
- [25] ZHAO Y, TUO J K, SHAN K X, et al. Review of Knowledge Tracing Models in Intelligent Education Field [J]. Computer System & Application, 2025(6):1-11.
- [26] SU Y, LIU Q W, LIU Q, et al. Exercise-Enhanced Sequential Modeling for Student Performance Prediction[C]// 32nd AAAI Conference on Artificial Intelligence/30th Innovative Applications of Artificial Intelligence Conference/8th AAAI Symposium on Educational Advances in Artificial Intelligence. 2018: 2435-2443.
- [27] NAKAGAWA H, IWASAWA Y, MATSUO Y. Graph-based knowledge tracing: Modeling student proficiency using graph neural networks[J]. Web Intelligence, 2021, 19(1/2): 87-102.
- [28] SONG X Y, LI J X, TANG Y F, et al. JKT: a joint graph convolutional network based deep knowledge tracing[J]. Information Sciences, 2021, 580: 510-523.
- [29] PENG Y T, MENG X F, DU Z J. Survey on Diversified Recommendation[J]. Journal of Computer Research and Development, 2025, 62(2): 285-313.
- [30] NABIZADEH H A, JORGE M A, LEAL P J. Estimating time and score uncertainty in generating successful learning paths under time constraints[J]. Expert Systems, 2019, 36(2): e12351.
- [31] HUANG Z Y, LIU Q, ZHAI C X, et al. Exploring Multi-Objective Exercise Recommendations in Online Education Systems [C]// 28th ACM International Conference on Information and Knowledge Management(CIKM). 2019:1261-1270.
- [32] ELSHANI L, NUCI K P. Constructing a personalized learning path using genetic algorithms approach[J]. arXiv: 2104. 11276, 2021.
- [33] REN Y M, LIANG K, SHANG Y H, et al. MulOER-SAN: 2-layer multi-objective framework for exercise recommendation with self-attention networks [J]. Knowledge-Based Systems, 2023, 260: 110117.
- [34] LIU Q, TONG S W, LIU C R, et al. Exploiting Cognitive Structure for Adaptive Learning[C]// 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD). 2019:627-635.
- [35] YU J F, LUO G, XIAO T, et al. MOOCube: A large-scale data repository for NLP applications in MOOCs[C]// Proceedings of the 58th Annual Meeting of the Association for Computational

- Linguistics, 2020;3135-3142.
- [36] LIU K J, ZHAO X, TANG J Y, et al. MOOPer; a large-scale dataset of practice-oriented online learning[C]//Proceedings of the 6th China Conference of Knowledge Graph and Semantic Computing: Knowledge Graph Empowers New Infrastructure Construction, 2021;281-287.
- [37] GAO Y. MOOCs video recommendation using low-rank and sparse matrix factorization with inter-entity relations and intra-entity affinity information[J]. Information Processing and Management, 2024, 61(6):103861.
- [38] CHEN X, SUN Y H, ZHOU T, et al. A Method on Online Learning Video Recommendation Method Based on Knowledge Graph[C]//12th IFIP TC 12 International Conference on Intelligent Information Processing(IIP 2022). 2022;419-430.
- [39] LYU J N, YANG B Y, GAO P, et al. Online course video recommendation based on weighted Heterogeneous Information Network fused with student characteristics[C]//2022 International Conference on Frontiers of Communications, Information System and Data Science(CISDS 2022). 2022;54-59.
- [40] WEN J F, QIN Y H, SU X W, et al. Video recommendation method based on multi-attention mechanism and heterogeneous information network [C] // 4th International Conference on Computer Engineering and Application (ICCEA 2023). 2023; 669-674.
- [41] GONG J B, WANG S, WANG J L, et al. Attentional Graph Convolutional Networks for Knowledge Concept Recommendation in MOOCs in a Heterogeneous View[C]//43rd International ACM SIGIR Conference on Research and Development in Information Retrieval(SIGIR). 2020;79-88.
- [42] SHENG D M, YUAN J L, XIE Q, et al. ACMF: An Attention Collaborative Extended Matrix Factorization Based Model for MOOC course service via a heterogeneous view[J]. Future Generation Computer Systems, 2022, 126:211-224.
- [43] CHEN X Y, SHEN J, XIA W, et al. Set-to-Sequence Ranking-Based Concept-Aware Learning Path Recommendation [C] // 37th AAAI Conference on Artificial Intelligence(AAAI)/35th Conference on Innovative Applications of Artificial Intelligence/13th Symposium on Educational Advances in Artificial Intelligence. 2023;5027-5035.
- [44] ZHANG H T, SHEN S H, XU B H, et al. Item-Difficulty-Aware Learning Path Recommendation: From a Real Walking Perspective[C]//30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2024;4167-4178.



**LIU Meilin**, born in 2001, postgraduate. Her main research interests include learning path recommendation and multi-objective optimization in recommender systems.



**MA Le**, born in 1983, Ph.D, associate professor, is a member of CCF (No. Z5803M). Her main research interests include learning mechanism modeling and affective computing.

(责任编辑:喻黎)