计 算 机 研 究 与 发 展
Journal of Computer Research and Development
https://crad.ict.ac.cn
62(8): 1884−1901, 2025

基于时空多粒度兴趣建模的学习资源推荐方法

朱海萍[1,2] 王子瑜[1] 赵成成[1] 陈 妍[1,2] 刘 均[1,2] 田 锋[1,3]
[1](西安交通大学计算机科学与技术学院 西安 710049)
[2](陕西省大数据知识工程重点实验室(西安交通大学) 西安 710049)
[3](大数据算法与分析技术国家工程实验室(西安交通大学) 西安 710049)
(zhuhaiping@xjtu.edu.cn)

Learning Resource Recommendation Method Based on Spatio-Temporal Multi-Granularity Interest Modeling

Zhu Haiping[1,2], Wang Ziyu[1], Zhao Chengcheng[1], Chen Yan[1,2], Liu Jun[1,2], and Tian Feng[1,3]
[1](*School of Computer Science and Technology*, *Xi'an Jiaotong University*, *Xi'an* 710049)
[2](*Shaanxi Provincial Key Laboratory of Big Data Knowledge Engineering* (*Xi'an Jiaotong University*), *Xi'an* 710049)
[3](*National Engineering Lab for Big Data Analytics* (*Xi'an Jiaotong University*), *Xi'an* 710049)

Abstract Personalized learning resource recommendation is derived from identifying learners' interests, recommending interesting and relevant learning resources accordingly. However, learners' interests are influenced by various factors such as knowledge points, learning resources, and courses, which makes it a challenging task to accurately represent their interests. Additionally, these interests evolve dynamically over time, complicating the task of identifying learning interest patterns. To address this challenge, we propose a learning resource recommendation method based on spatio-temporal multi-granularity interest modeling, which is characterized as follow: An innovative architecture is designed and implemented for learning interest representation that integrates the learning space and temporal dimension in a heterogeneous graph-based learning space and the multi-granularity interest representation. The nodes in this graph represent entities, such as knowledge points, learning resources, courses, teachers, and schools; and the edges of the graph represent the inter-entity relationships. A graph neural network is utilized to express the multi-granularity interest in these nodes. Moreover, we propose a temporal multi-granularity interest pattern representation method by combining multi-dimensionality of time, learning space, and course preference, and slicing through the sequence of learner's historical behaviors is used to mine the learner's different granularity of interest patterns in the near-term within-course, mid-term across-course, and long-term across-course. Then, a multi-granularity interest adaptive fusion layer is proposed to fuse multi-granularity interest representations and interest patterns. Based on this method, a multi-granularity interest self-supervision task is designed to solve the problem of lack of supervised signaling for spatio-temporal multi-granularity interests, and recommend relevant learning resources for learners via prediction layer. Our experimental results show that the proposed method outperforms the optimal comparison algorithms HinCRec in *Recall*@20 and *NDCG*@20 metrics by 3.13% and 7.45% on MOOCCube dataset, respectively, and outperforms optimal comparison algorithm HinCRec in *Recall*@20 and *NDCG*@20 metrics

收稿日期: 2024-04-03; **修回日期**: 2024-10-23
基金项目: 国家重点研发计划项目(2022YFC3303600); 国家自然科学基金项目(62277042, 62293551, 62177038, 62377038); 中国工程科技知识中心项目; 联想-西安交通大学智慧行业联合实验室项目
This work was supported by the National Key Research and Development Program of China (2022YFC3303600), the National Natural Science Foundation of China (62277042, 62293551, 62177038, 62377038), the Project of China Knowledge Centre for Engineering Science and Technology, and the "LENOVO-XJTU" Intelligent Industry Joint Laboratory Project.
通信作者: 田锋(fengtian@mail.xjtu.edu.cn)

by 4.87% and 7.03% on MOOPer dataset, respectively.

Key words recommendation system; learning resource recommendation; multi-granularity interest modeling; graph neural network; sequential modeling

摘 要 个性化学习资源推荐以提取学习者兴趣为基础，为学习者推荐感兴趣的学习资源. 然而，学习者的兴趣不仅受知识点、学习资源、课程等因素影响导致其兴趣难表征，而且其会随时间推移动态变化使得学习兴趣模式难捕获. 针对此，提出基于时空多粒度兴趣建模的学习资源推荐方法，其特点在于：设计并实现了一种融合学习空间和时间维度的学习兴趣表征学习架构，其中，首先提出基于异构图的学习空间及其多粒度兴趣表征，即用节点表示知识点、学习资源、课程、教师和学校等实体，边表示实体间关系，用此异构图表示学习空间，再通过图神经网络表征学习节点嵌入来表达节点上的多粒度兴趣；然后提出时间维度多粒度兴趣模式表征方法，即结合时间、学习空间和课程偏好等多维度，切分学习者历史行为序列，用于挖掘学习者近期课程内、中期跨课程和长期跨课程等不同粒度的兴趣模式，并设计多粒度兴趣自监督任务，破解时空多粒度兴趣缺少监督信号问题；最后，提出多粒度兴趣自适应融合层，将多粒度兴趣表征和兴趣模式融合，获得最终的学习者兴趣，经预测层为学习者推荐感兴趣的学习资源. 实验结果表明，在 MOOCCube 数据集上，所提算法较最优对比算法 HinCRec，在 *Recall*@20 和 *NDCG*@20 指标上分别提升了 3.13%，7.45%；在 MOOPer 数据集上，所提算法较最优对比算法 HinCRec 在 *Recall*@20 和 *NDCG*@20 指标上分别提升了 4.87%，7.03%.

关键词 推荐系统；学习资源推荐；多粒度兴趣建模；图神经网络；序列建模

中图法分类号 TP18；TP391

DOI: 10.7544/issn1000-1239.202440249 **CSTR:** 32373.14.issn1000-1239.202440249

教育资源推荐系统是一种典型的数据驱动信息系统服务，根据其对学习者建模的目标可分为面向学习者兴趣、面向学习者学习表现、面向学习者认知水平和面向学习者学习风格的推荐[1]. 文献 [2] 指出如何从大量的用户历史交互数据中精准发现用户兴趣是个性化学习资源推荐算法的核心，因此，本文主要研究面向学习者兴趣的推荐. 学习者兴趣不仅体现在课程、知识点、资源层面，而且与时间维度信息相关.

传统的学习资源推荐方法[3-6]往往聚焦于学习者对学习资源本身的兴趣，使用单一向量表征学习者的兴趣偏好，易导致兴趣表征不充分问题. 对此，有学者们已开始研究用户多兴趣建模[7-10]，通过为每个用户学习多个兴趣向量，每个向量表达用户兴趣的不同方面，更全面地表征用户兴趣. 但现有研究忽略了在知识概念上对知识点、学习资源、课程等多粒度的兴趣表征；且大多仅从时间维度上简单切分用户历史行为序列[9-10]并在此序列内发现兴趣模式. 如图 1(a)所示，直接根据时间将最后 4 个资源的序列建模为学习者近期兴趣，整个序列建模为学习者长期兴趣，忽略了在学习空间和时间 2 个维度上多粒度之间的关联关系，导致难以捕获学习者动态多变的学习兴趣模式.

本文选取学堂在线公开数据集 MOOCCube Q&A 中学习者关于 14 门课程的学习日志，对学习者历史行为序列进行分析. 图 2 统计了学习者所学习的课程数，由图 2 可知，大部分学习者在该平台学习多门课程，且集中在 2~5 门课程. 结合 2.3 节中不同时间维度下用户学习的课程数量统计，本文分析发现：学习者的兴趣随时间动态变化，受学习资源、课程等影响较大. 图 1 给出了现有学习资源推荐方法和本文所提方法的比对. 如图 1(b)所示，竖线填充圆圈和横线填充圆圈分别是“操作系统”课程和“数据结构”课程的视频资源，一个学习序列不仅体现了学习资源的先后学习顺序，且蕴含了学习者在不同时期对不同课程的学习偏好. 从图 1(b)中可以看出，学习者在 (t_2, t_3) 时间内集中学习“数据结构”课程内的多个学习资源，在 (t_1, t_3) 的时间内同时学习了“数据结构”和“操作系统”2 门课程，用户的学习兴趣模式从单一课程学习到跨课程学习发生了改变. 故现有序列建模方法不但无法表征学习空间上的多粒度信息，而且也无法捕获用户在课程上的学习兴趣模式变化，即无法有效捕获多粒度的学习空间和学习时间 2 个维度上的兴趣模式变化.

针对此，本文提出基于时空多粒度兴趣建模的学习资源推荐算法，从时间和学习空间进行多粒度的学习兴趣表征和兴趣模式挖掘，进而为学生提供

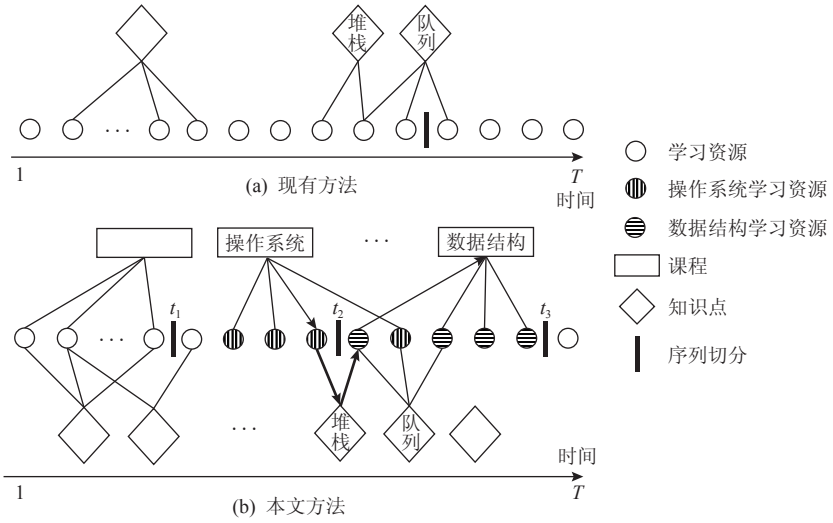


Fig. 1 Example of method comparison

图 1 方法对比示例

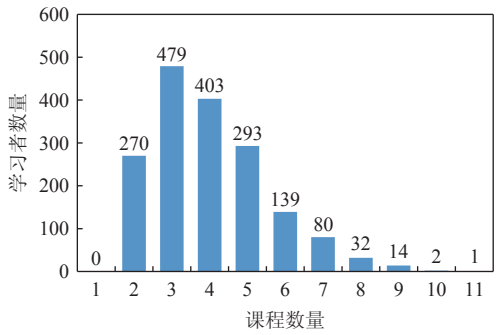


Fig. 2 Statistical chart of the number of courses taken by learners

图 2 学习者学习课程数统计图

感兴趣的资源推荐.

首先, 提出一种基于异构图的图数据构建方法学习空间数据构建, 即用节点表示知识点、学习资源、课程、教师和学校等实体, 边表示实体间关系; 其次, 提出图神经网络的多粒度兴趣表示学习, 提取学习者在知识点、学习资源、课程上的多粒度兴趣表征; 再者, 提出时间维度多粒度兴趣模式表征方法, 即结合时间、学习空间和课程偏好等多维度, 切分学习者历史行为序列, 用于挖掘学习者近期课程内、中期跨课程和长期跨课程等不同粒度的兴趣模式; 进而, 提出时间维度上的多粒度兴趣自监督任务, 缓解缺少监督信号的问题, 显式区分不同粒度的兴趣向量, 增强同一粒度兴趣向量的表达; 最后, 使用注意力机制, 自适应地融合学习空间和时间维度的多粒度兴趣向量, 将学习者表征向量、融合后的兴趣向量、学习资源表征向量输入至预测层, 为学习者推荐合适的学习资源.

本文所提基于时空多粒度兴趣建模的学习资源推荐方法的主要贡献有 3 个方面:

1)设计并实现融合学习空间和时间维度的学习兴趣表征学习架构, 其中, 提出异构图的学习空间及其之上的兴趣表征学习, 解决学习空间上多粒度用户兴趣难表征问题; 基于时间维度的多粒度兴趣表征学习方法, 不但兼顾课程偏好和时间属性, 而且可对学习者近期课程内、中期跨课程和长期跨课程等不同粒度的兴趣表征并学习, 有效解决时间维度上用户多粒度兴趣模式的表征问题.

2)使用注意力机制, 自适应地融合学习空间和时间维度的多粒度兴趣向量, 有效解决多粒度的时间和学习空间 2 个维度上的兴趣模式捕获难题.

3)在 MOOCCube 数据集和 MOOPer 数据集上的实验结果表明所提算法在性能指标上优于对比算法, 验证了方法的有效性.

1 相关工作

本节主要概述与本文研究相关的学习资源推荐以及推荐中的用户兴趣建模研究现状.

1.1 学习资源推荐

学习资源推荐根据其对学习者建模的目标可以分为面向学习者兴趣、面向学习者学习表现、面向学习者认知水平和面向学习者学习风格的推荐, 本文主要关注面向学习者兴趣的学习资源推荐.

在面向学习者学习表现的资源推荐方面, 知识追踪方法取得了不错的表现, 例如 Ai 等人[11] 对动态键值记忆网络进行了修改, 以课程概念表为基础设

计其记忆结构，在学习者的知识追踪过程中明确考虑了习题与概念的映射关系，并使用强化学习的策略进行学习资源推荐. Huang 等人[12] 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，达到了更好的推荐效果. Huo 等人[13] 提出一种基于 LSTM 的知识追踪方法，该模型嵌入了知识组件的上下文，实现了知识的上下文表示. Wu 等人[14] 提出了一种新的习题推荐方法，利用循环神经网络（RNN）预测知识概念的覆盖范围，并根据学生的习题答题记录，利用深度知识追踪（DKT）预测学生对知识概念的掌握程度.

在面向学习者认知水平的资源推荐方面，一些研究根据学习者的认知水平为学习者推荐难度合适的学习资源，胡园园等人[15] 通过分析学习者已学课程和所得的课程成绩，建模学习者与学习资源之间的适配度进行推荐. Ren 等人[16] 根据学习者多模态反馈（个人信息、评论、收藏和点赞等信息）建模学习者认知水平，选择合适的课程进行推荐. 在面向学习者学习风格的资源推荐方面，Nafea 等人[17] 使用 Felder-Silverman 学习风格模型（FSLSM）建模学生的学习风格进行推荐.Wan 等人[18] 提出了一种基于混合概念映射和免疫算法的推荐算法，为学习者推荐符合学习者学习风格的学习路径.

在面向学习者兴趣的资源推荐方面，Yan 等人[19] 提出一种基于协同过滤和关联规则挖掘的混合推荐算法，并在算法中融入学习者的学习兴趣. Gong 等人[20] 将深度协同过滤组件与宽线性组件结合，在利用学习者和学习资源特征的基础上，引入学习资源的其他特征（如难度、类型和知识点）进行混合推荐. 图结构在表征实体概念之间的联系方面具有巨大的优势，一些基于图结构的推荐算法[21-26] 也取得了优秀的表现. 如刘雨[21] 提出使用 GRU 建模学习者的长短期兴趣偏好，并引入图嵌入技术提升推荐效果. Gong 等人[22] 和 Wang 等人[23] 构建学习者-课程-学习视频-知识点异质信息网络，使用基于元路径的图表征方法建模用户兴趣，将节点表征输入到矩阵分解模块，为学习者个性化推荐知识点. Zhang 等人[25] 将学习者的行为和课程图谱自然地投射到一个统一的空间中，从而缓解了课程推荐中的交互模糊性、课程相关性和意图多样性等难题，更好地建模了学习者兴趣.

综上，学习资源推荐是在线教育领域持续研究的热点问题，精准建模学习者的兴趣偏好是面向学习者兴趣的学习资源推荐算法的关键. 近年来对学习资源推荐的研究有了较大进展，有效挖掘了学习者的学习兴趣. 但是，现有学习资源推荐算法往往聚焦于学习者对学习资源本身的单粒度兴趣，对学习者的多粒度兴趣建模不足，即大多使用单一向量表征学习者复杂多样的兴趣偏好，易导致兴趣表征不充分问题.

1.2 用户兴趣建模

用户兴趣建模是推荐算法的核心，使用单一向量表征用户兴趣的单粒度兴趣建模最早得到了研究者们的关注. Zhou 等人[27] 通过将目标物品和用户历史行为序列中的物品做 Attention，实现用户历史兴趣的局部激活. Zhou 等人[28] 设计了兴趣提取层和兴趣演化层来建模用户兴趣的演化. 在兴趣提取层，使用 GRU 建模用户历史行为序列的依赖关系，将 GRU 的隐层输出作为用户兴趣的表达向量；在兴趣演化层，提出使用 AUGRU 建模用户兴趣的演化. Chen 等人[3] 使用 Transformer 挖掘用户历史行为序列背后的兴趣. Sun 等人[4] 将 NLP 中的 BERT 模型迁移至推荐的用户序列建模中以提取用户兴趣. 陈碧毅等人[5] 在使用加权低秩方法处理用户隐式反馈数据的基础上，结合用户的显示反馈数据训练用户的兴趣表征. Zheng 等人[6] 通过构建自监督任务，提取用户历史行为中的长期兴趣和短期兴趣.

用户的兴趣复杂多样，单一向量难以表征用户的全部兴趣，对此，学者们开始研究用户多兴趣建模. Li 等人[7] 和 Cen 等人[9] 设计了一种基于胶囊路由机制的多兴趣提取层，将用户的历史行为分组到多个兴趣胶囊中，使用动态路由来自适应聚合用户行为和提取多个表示用户兴趣的向量. Cao 等人[29] 引入知识图谱，并将用户兴趣与知识图谱中的关系一一对应，以此获得用户的多兴趣向量. Wang 等人[30] 引入多个意图节点，将原始图分解为多个子图，每个子图对应一个意图，代表用户兴趣的某个方面. Wang 等人[31] 则将用户的每个兴趣都由知识图谱中的所有关系聚合.

随着用户多兴趣建模研究的深入，有学者指出用户的兴趣是多粒度的，忽略用户兴趣的粒度，可能造成学习到的多兴趣表征带有噪声，且可解释性较差[32]. 针对此，区分用户兴趣粒度的推荐算法开始受到学者们的关注. Qi 等人[32] 通过构建用户分层兴趣树，提取用户对新闻一级类别、二级类别和总体不同粒度的兴趣.Guo 等人[33] 将用户会话序列划分为不同长短粒度的时序会话片段，提出多粒度意图异构会话图（MIHSG）来捕捉不同粒度意图单元间的交互，以此获取用户兴趣. 该类算法进一步提升了推荐效果.

但是, 现有多粒度兴趣建模方法往往仅从时间维度切分并建模用户历史行为序列, 忽略了学习者在学习空间对知识点、学习资源、课程等不同粒度实体的兴趣. 此外, 在 2 个公开的网络学习数据集 MOOCCube 和 MOOPer 数据集上分析发现, 学习者的兴趣随时间推移动态变化的同时受课程影响较大(详细参见 2.2 节), 仅从时间维度对历史学习行为序列切分, 难以捕获用户学习兴趣和课程之间的依赖关系, 易造成学习者兴趣表征欠佳, 进而影响学习资源推荐效果, 因此, 现有多粒度兴趣建模方法难以直接应用于学习资源推荐中.

2 基于时空多粒度兴趣建模的学习资源推荐方法

基于时空多粒度兴趣建模的学习资源推荐方法整体结构如图 3 所示, 主要由学习空间多粒度兴趣表征建模模块、时间维度多粒度兴趣模式发现模块和学习资源推荐模块组成. 本节将详述这 3 个模块.

2.1 问题定义

在学习资源推荐场景, 存在丰富的知识概念实体, 如知识点、学习资源、课程、教师等, 这些实体以及实体间关系蕴含着丰富的信息. 本文要解决的问题是在已知用户在线学习历史记录和知识概念实体关系的条件下, 为用户进行学习资源推荐, 以满足用户需求.

问题具体定义为: U表示所有用户, V表示所有的学习资源, R表示已知的知识概念实体关系, 对于每一个用户$u \in U$, 根据其在线学习历史记录$H_u = \{v_1, v_2, \cdots, v_n\}$和知识概念实体关系$R$, 为用户推荐下一个可能学习的资源$v_{n+1}$, 其中, $v_i \in V$, n表示历史记录长度.

2.2 学习空间多粒度兴趣表征建模模块

以异构图来对知识点、学习资源、课程等知识概念实体关系建模的思想为指导, 学习空间多粒度兴趣表征建模模块旨在实现基于异构图的学习空间构建及其之上的多粒度兴趣表征学习, 包括基于异构图的学习空间构建、边信息感知的图神经网络表征、学习空间多粒度兴趣提取 3 个步骤.

第 1 步. 根据知识概念实体关系构建基于异构图的学习空间$G_u = \langle N_u, E \rangle$, 用节点表示知识点、学习资源、课程、教师和学校等实体$N_u = k \cup v \cup c \cup t \cup s$, 其中$v$是$H_u$中所有学习资源构成的集合, k,c,t,s表示所有与v相关联的知识点、课程、教师、学校等节点, 满足$\forall n \in k \cup c \cup t \cup s$, (n,v)在R中是连通的; 边集合表示实体间关系, 根据R对所有节点进行边集合的构建, 定义为$\forall n_1, n_2 \in N_u$, 若$(n_1, n_2) \in R$, 则$(n_1, n_2) \in E$. 图 4 是由实体节点、虚拟类型节点以及节点间不同类型边构成的异构图, 节点和边信息参见表 1 和表 2. 其中, 虚拟类型节点是为了在提取多粒度兴趣时有效利用

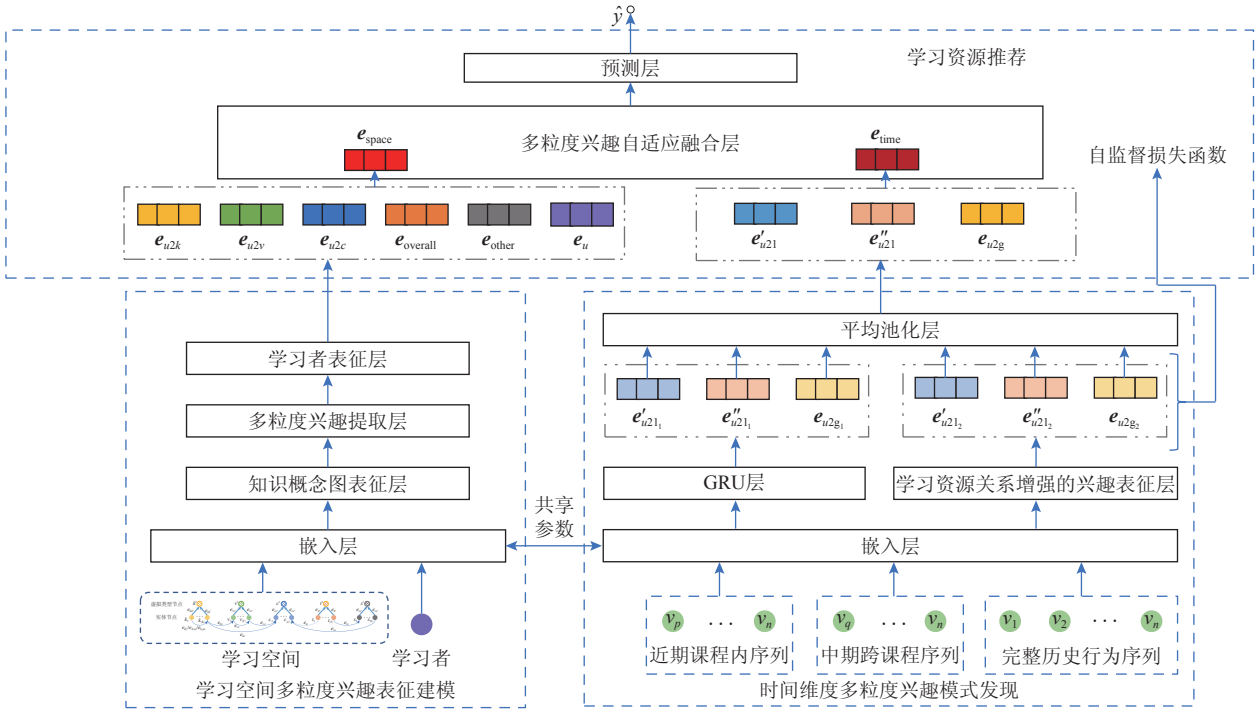


Fig. 3 Structure framework of learning resource recommendation method based on spatio-temporal multi-granularity interest modeling

图 3 基于时空多粒度兴趣建模的学习资源推荐方法结构图

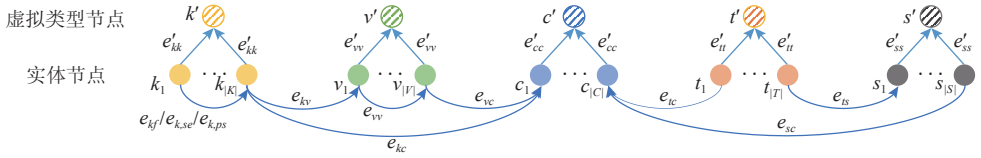


Fig. 4 Learning space based on heterogeneous graph

图 4 基于异构图的学习空间

Table 1 Node Information for Learning Space

表 1 学习空间节点信息

节点类型	符号	名称
实体节点	k	知识点节点
	v	学习资源节点
	c	课程节点
	t	教师节点
	s	学校节点
虚拟类型节点	k'	知识点虚拟类型节点
	v'	学习资源虚拟类型节点
	c'	课程虚拟类型节点
	t'	教师虚拟类型节点
	s'	学校虚拟类型节点

Table 2 Edge Information for Learning Space

表 2 学习空间边信息

符号	名称	含义
e_{kf}	知识点-知识点类别边	知识点所属类别
$e_{k,se}$	前驱知识点-后继知识点边	知识点间先后序关系
$e_{k,ps}$	父知识点-子知识点边	知识点间父子关系
e_{kv}	知识点-学习资源边	学习资源与知识点的包含关系
e_{kc}	知识点-课程边	课程与知识点的包含关系
e_{vv}	学习资源先后序关系边	学习资源在课程中先后序关系
e_{vc}	学习资源-课程边	课程与学习资源间的包含关系
e_{sc}	学校-课程边	所开设课程的学校
e_{tc}	教师-课程边	课程与任课教师关系
e_{ts}	教师-学校边	教师与所任教学校关系
$e_{kk'}$	知识点间虚拟类型节点边	知识点间虚拟类型节点关系
$e_{vv'}$	学习资源间虚拟类型节点边	学习资源间虚拟类型节点关系
$e_{cc'}$	课程-课程虚拟类型节点边	课程与课程虚拟类型节点关系
$e_{tt'}$	教师-教师虚拟类型节点边	教师与教师虚拟类型节点关系
$e_{ss'}$	学校-学校虚拟类型节点边	学校与学校虚拟类型节点关系

不同类型节点的信息，且避免直接聚合节点引入噪声的问题，为每种类型实体节点设计的虚拟节点.

考虑到学习者在选择学习资源时，会考虑学习资源的授课教师以及教师所在学校，如：某学习者喜欢学习某老师的课程或某学校老师的课程，本文在学习关系异构图中引入了教师节点和学校节点.

第 2 步. 边信息感知的图神经网络表征. 兴趣表征建模模块的输入为学习者、学习资源的 ID 特征，以及知识概念异质图中全部知识概念节点、虚拟类型节点和不同类型边的 ID 特征. 本文将所有 ID 特征表示为稀疏向量，$\boldsymbol{x}_{u_i}\in\mathbb{R}^{1\times|U|}$是第$i$个学习者的独热(one-hot)向量；$\boldsymbol{x}_{v_j}\in\mathbb{R}^{1\times|V|}$是第$j$个学习资源的独热向量. 知识概念异质图中的知识点、学习资源、课程、教师和学校节点的 ID 特征分别表示为$\boldsymbol{x}_k\in\mathbb{R}^{|K|\times|K|}$，$\boldsymbol{x}_v\in\mathbb{R}^{|V|\times|V|}$，$\boldsymbol{x}_c\in\mathbb{R}^{|C|\times|C|}$，$\boldsymbol{x}_t\in\mathbb{R}^{|T|\times|T|}$和$\boldsymbol{x}_s\in\mathbb{R}^{|S|\times|S|}$. 由于 ID 类别特征的独热向量维度和稀疏性较高，通过引入嵌入层，得到其低维稠密的嵌入向量可缓解该问题. 本文使用式(1)得到第i个学习者的嵌入向量$\boldsymbol{e}_{u_i}\in\mathbb{R}^{1\times d}$.

$$\boldsymbol{e}_{u_i}=\boldsymbol{x}_{u_i}\boldsymbol{E}_u, \tag{1}$$

其中$\boldsymbol{E}_u\in\mathbb{R}^{|U|\times d}$是学习者的嵌入向量矩阵，同理可获得第$j$个学习资源的嵌入向量$\boldsymbol{e}_{v_j}\in\mathbb{R}^{1\times d}$、虚拟类型节点的嵌入向量矩阵$\boldsymbol{e}_{\text{virtual_type_node}}\in\mathbb{R}^{5\times d}$、边的嵌入向量矩阵$\boldsymbol{e}_{\text{edge}}\in\mathbb{R}^{15\times d}$. 其中虚拟类型节点的嵌入向量矩阵$\boldsymbol{e}_{\text{virtual_type_node}}$包括表 1 中知识点虚拟类型节点的嵌入向量$\boldsymbol{e}_{k'}\in\mathbb{R}^{1\times d}$到学校虚拟类型节点的嵌入向量矩阵$\boldsymbol{e}_{s'}\in\mathbb{R}^{1\times d}$；边的嵌入向量矩阵$\boldsymbol{e}_{\text{edge}}$包括表 2 中知识点-知识点类别边嵌入向量$\boldsymbol{e}_{e_{kf}}\in\mathbb{R}^{1\times d}$到学校-学校虚拟类型节点边嵌入向量$\boldsymbol{e}_{e_{ss'}}\in\mathbb{R}^{1\times d}$.

由于异构图中边的类型非常丰富，本文在得到所有特征的嵌入向量后，使用边信息感知的图神经网络表征算法[29]，进行学习空间图表征学习，见式(2).

$$\boldsymbol{e}_{\text{dst}}^{(l+1)}=\frac{1}{|\mathcal{N}(dst)|}\sum_{(\boldsymbol{e}_{\text{src}},\boldsymbol{e}_{\text{edge}},\boldsymbol{e}_{\text{dst}})\in\mathcal{N}(dst)}\left(\boldsymbol{e}_{\text{src}}^{(l)}\odot\boldsymbol{e}_{\text{edge}}^{(l)}\right). \tag{2}$$

第 3 步. 学习空间多粒度兴趣提取. 本文将学习者在学习空间中的兴趣节点划分为知识点粒度、学习资源粒度、课程粒度、总体粒度，分别提取学习者在各粒度上的兴趣. 其中，总体粒度兴趣节点和所有虚拟类型节点相连，其他兴趣节点和教师虚拟类型节点以及学校虚拟类型节点相连.

以知识点粒度兴趣提取为例，构建由知识点虚拟类型节点和知识点相关边的表征向量组成的集合$\boldsymbol{e}_{\text{knowledge}}$，具体见式(3).

$$\boldsymbol{e}_{\text{knowlege}}=\{\boldsymbol{e}_k,\boldsymbol{e}_{e_{kf}},\boldsymbol{e}_{e_{k,se}},\boldsymbol{e}_{e_{k,ps}},\boldsymbol{e}_{e_{kv}},\boldsymbol{e}_{e_{kc}},\boldsymbol{e}_{e_{kk'}}\}. \tag{3}$$

考虑到集合中不同节点和边对知识点粒度兴趣

的贡献程度不同[31], 使用注意力机制计算节点和边对知识点粒度兴趣的重要程度分数, 按照注意力分数聚合节点和边的表征向量得到学习者的知识点粒度兴趣向量. 知识点粒度兴趣向量的计算公式见式(4), 注意力机制计算公式见式(5).

$$\boldsymbol{e}_{u2k}=\sum_{\boldsymbol{e}_{k,i}\in e_{\text{knowledge}}}\alpha(k,i)\boldsymbol{e}_{k,i}, \tag{4}$$

$$\alpha(k,i)=\frac{\exp(w_{k,i})}{\sum_{j=1}^{k}\exp(w_{k,j})}, \tag{5}$$

其中$\boldsymbol{e}_{u2k}\in\mathbb{R}^{1\times d}$是学习者在知识点粒度的兴趣向量, $\boldsymbol{e}_{k,i}\in\mathbb{R}^{1\times d}$是知识点虚拟类型节点或知识点相关边的表征向量, 即为集合$e_{\text{knowledge}}$中的第i个元素, $\alpha(k,i)$是$\boldsymbol{e}_{k,i}$对$\boldsymbol{e}_{u2k}$的重要程度权重, $w_{k,i}$和$w_{k,j}$是可学习参数.

类似地, 可分别提取学习者在学习资源粒度的兴趣向量$\boldsymbol{e}_{u2v}$、学习者在课程粒度的兴趣向量$\boldsymbol{e}_{u2c}$、学习者在总体粒度的兴趣向量$\boldsymbol{e}_{\text{overall}}$和其他兴趣向量$\boldsymbol{e}_{\text{other}}$. 其中, 总体粒度的兴趣向量$\boldsymbol{e}_{\text{overall}}$由所有虚拟类型节点($k'$, v', c', t', s')和所有类型边的表征向量组成的集合构建而来. 其他兴趣向量$\boldsymbol{e}_{\text{other}}$由教师和学校虚拟类型节点($t'$, s'), 以及教师和学校相关边的表征向量组成的集合构建而来.

2.3 时间维度多粒度兴趣模式发现模块

时间维度多粒度兴趣模式发现模块旨在兼顾学习空间和时间维度上的多粒度偏好, 可对学习者近期课程内、中期跨课程和长期跨课程等不同粒度的兴趣表征并发现其兴趣模式, 包括序列建模、学习资源关系增强的学习者兴趣表征、时空多粒度兴趣模式提取和时空多粒度兴趣自监督任务4个步骤. 值的注意的是, 该模块的嵌入层和学习空间多粒度兴趣建模模块中的嵌入层共享参数.

第1步. 序列建模. 本文在MOOCCube和MOOPer数据集上进行用户学习序列切分及不同区间内学习课程门数的统计与分析. 首先根据时间维度将每个学习者历史行为序列平均分成3个区间, 选取距离当前时间T最近的区间作为近期区间, 最近的2个区间作为中期区间, 分别统计区间内的学习者平均学习课程门数. 如表3所示, 近期区间上学习的平均课程数在2个数据集上均为1~2, 说明在近期内学习者的兴趣主要集中在1门课程. 中期区间和长期区间上学习的平均课程数呈递增态势, 且增幅均大于1, 表明学习者的课程偏好随时间推移动态变化. 跨课程序列占比显示大多数学习者均存在跨课程学习的情况.

Table 3 Statistical Information of Course Type

表3 课程种类统计信息

数据集	近期平均课程数	中期平均课程数	长期平均课程数	跨课程序列占比/%
MOOCCube	1.29	2.83	5.24	74.34
MOOPer	1.76	3.05	7.36	89.51

根据以上数据分析结果, 本文设计结合时间序列和课程偏好的序列切分方式, 将学习者的历史行为序列切分为近期课程内、中期跨课程和长期跨课程3个历史行为序列. 图5给出了基于课程偏好的序列切分示意图, 其中每个圆圈表示一个学习资源, 不同的形状填充表示学习资源属于不同的课程. 在划分学习者近期课程内历史行为序列时, 统计近期区间内课程的种类以及数量, 选取占比最多的课程作为用户的近期偏好课程, 在近期区间内找到学习者第1次学习近期偏好课程下的学习资源, 以此作为序列切分的左边界. 同理, 在划分学习者中期跨课程历史行为序列时, 选取除近期偏好课程外占比最多的课程作为用户的中期偏好课程, 在中期区间内找到学习者第1次学习近期偏好课程或中期偏好课程下的学习资源, 以此作为序列切分的左边界, 这样切分有助于更好地获取用户在知识点、学习资源和课程上的多粒度学习偏好.

在得到近期课程内序列和中期跨课程序列后, 结合学习者完整历史行为序列, 进行3种序列的建模, 建模过程分为嵌入层和GRU层2部分.

1)嵌入层

将学习者上述各历史行为序列输入至嵌入层,

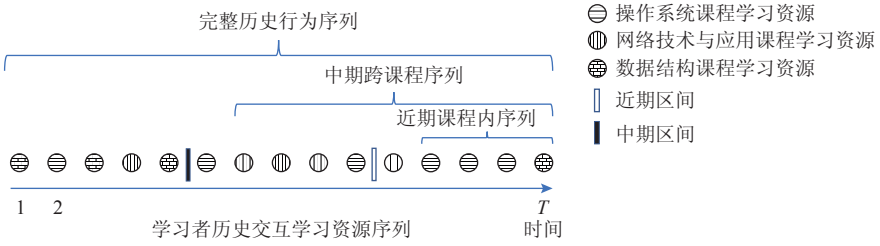


Fig. 5 Illustration of user behavior sequence segmentation based on course preference

图5 基于课程偏好的用户行为序列切分示意图

如式(6)所示.

$$\boldsymbol{e}_{v_i} = \boldsymbol{x}_{v_i}\boldsymbol{E}_v, \tag{6}$$

其中$\boldsymbol{E}_v \in \mathbb{R}^{|V|\times d}$是学习资源的嵌入向量矩阵，与学习空间多粒度兴趣表征建模模块中相同，即嵌入层参数共享. $\boldsymbol{x}_{v_i}$表示切分后各序列中的学习资源输入向量.

经过嵌入层后得到学习者近期课程内序列嵌入向量$\boldsymbol{e}_{\text{seq_l}'}$、中期跨课程序列嵌入向量$\boldsymbol{e}_{\text{seq_l}''}$和长期跨课程序列嵌入向量$\boldsymbol{e}_{\text{seq_g}}$，如式(7)~(9)所示.

$$\boldsymbol{e}_{\text{seq_l}'} = (\boldsymbol{e}_{v_p}, \boldsymbol{e}_{v_2}, \cdots, \boldsymbol{e}_{v_n}), \tag{7}$$

$$\boldsymbol{e}_{\text{seq_l}''} = (\boldsymbol{e}_{v_q}, \boldsymbol{e}_{v_2}, \cdots, \boldsymbol{e}_{v_n}), \tag{8}$$

$$\boldsymbol{e}_{\text{seq_g}} = (\boldsymbol{e}_{v_1}, \boldsymbol{e}_{v_2}, \cdots, \boldsymbol{e}_{v_n}), \tag{9}$$

其中n是学习者完整历史行为序列的长度，p是学习者近期课程内历史行为序列的左边界下标，q是学习者中期跨课程历史行为序列的左边界下标.

2)GRU层

GRU是用户建模的表征学习中常用关键技术，主要用于挖掘用户历史行为序列中的关联关系，抽取序列数据中的高阶信息.GRU的优势在于，其解决了RNN梯度消失的问题，且模型结构比LSTM更简单、参数更少、训练速度更快、不易过拟合. 因此，本文选用GRU建模学习者的历史行为序列. GRU的主要训练过程如下.

GRU包含更新门和重置门，时刻$t-1$隐藏层状态向量$\boldsymbol{h}_{t-1}$和时刻t候选隐藏层状态向量$\hat{\boldsymbol{h}}_t$共同影响时刻t隐藏层状态向量$\boldsymbol{h}_t$，具体计算公式为

$$\boldsymbol{h}_t = (1-\boldsymbol{z}_t)\boldsymbol{h}_{t-1} + \boldsymbol{z}_t\hat{\boldsymbol{h}}_t. \tag{10}$$

由于不同学习者的学习序列长度不一致，我们将经过嵌入层得到的每个学习者近期课程内历史行为序列嵌入向量$\boldsymbol{e}'_{\text{seq_l}}$、中期跨课程历史行为序列嵌入向量$\boldsymbol{e}''_{\text{seq_l}}$和长期跨课程序列嵌入向量$\boldsymbol{e}_{\text{seq_g}}$分别进行填充，填充长度分别为各自个体切分后的最大长度. 将填充之后的近期课程内历史行为序列嵌入向量、中期跨课程历史行为序列嵌入向量和长期跨课程序列嵌入向量分别输入到GRU层，可获得学习者近期课程内兴趣向量$\boldsymbol{e}'_{u2\text{l}_1}$、中期跨课程兴趣向量$\boldsymbol{e}''_{u2\text{l}_1}$和长期跨课程兴趣向量$\boldsymbol{e}_{u2\text{g}_1}$.

第2步. 学习资源关系增强的学习者兴趣表征. 在将学习者的历史行为序列切分为近期课程内、中期跨课程序列后，可能存在序列长度较短导致兴趣提取难度大的问题. 然而，学习资源推荐的特点是学习资源间存在较强的关联性，学习资源间的关联信息可用于辅助描述学习者所交互的学习资源间的关系. 对此，本文提出一种学习资源关系增强的学习者兴趣表征方法. 如图6所示，首先使用学习者历史行为序列，构建学习者学习行为图；其次，利用学习者所学习的学习资源间的关系，构建学习资源图；最后，融合学习者学习行为图和学习资源图，得到学习行为-学习资源图. 下面详细介绍构建学习者学习行为图、学习资源图、学习资源关系增强的学习者兴趣表征方法的过程.

1)构建学习者行为图

借鉴已有基于图的会话推荐方法[34]，通过为学习者历史行为序列中相邻学习资源添加有向边，构建学习者历史行为图. 例如，给定学习者历史行为序列$seq=(v_{11},v_{13},v_{14},v_{13},v_{23},v_{21})$，其中，$v_{11}$，$v_{13}$，$v_{14}$，$v_{21}$，$v_{23}$是学习者历史交互的学习资源，构建的学习行为图如图6左边部分所示.

2)构建学习资源图

根据学习者所学习的相关学习资源间关系$R_v \subset R$，为存在前后序关系的学习资源添加有向边，构建学习资源图. 如v_i为v_j的前序必修课程，则添加有向边$v_i \to v_j$. 给定上述学习者所交互的学习资源序列，构建的学习资源图如图6中间部分所示.

3)构建学习资源-学习行为图

如图6右边部分所示，将学习资源图和学习者学习行为图融合为学习资源-学习行为图. 学习者近期课程内、中期跨课程和长期跨课程历史行为序列可分别构建其学习资源-学习行为图.

在此基础上，通过学习资源关系增强的学习者兴趣表征层获得学习资源关系增强的学习者各粒度兴趣向量，该层主要包含基于GGNN的表征学习层

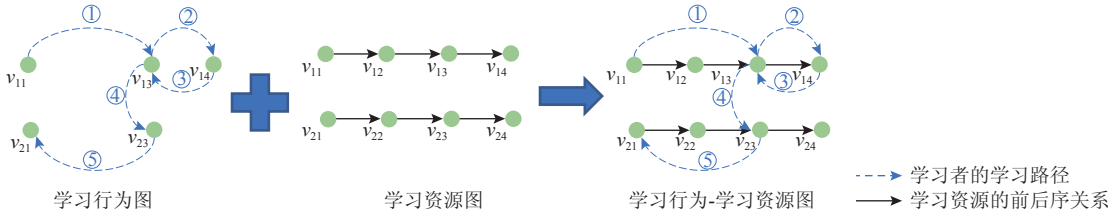


Fig. 6 Illustration of the process for constructing a graph of learning behaviors and learning resources

图6 学习行为-学习资源图构建过程示意图

和 Readout 层.

1)基于 GGNN 的表征学习层

借鉴文献 [35] 中使用的 GGNN 刻画用户在会话内的迁移关系,本文使用基于 GGNN 的表征学习刻画学习资源-学习行为图中复杂的关系. 基于 GGNN 的表征学习层信息聚合方式如式(11)所示,更新方式如式(12)~(15)所示. 经过基于 GGNN 的表征学习后,可获得学习资源-学习行为图的节点表征$\boldsymbol{h}^{(l+1)}$,记作$\boldsymbol{e}_V^{(l+1)}$.

$$\boldsymbol{h}_{N_v}^{(l+1)}=\sum_{u\in N_v}\boldsymbol{h}_u^{(l)}+\boldsymbol{b}, \tag{11}$$

$$\boldsymbol{z}_v^{(l+1)}=\sigma\left(\boldsymbol{W}^z\boldsymbol{h}_{N_v}^{(l+1)}+\boldsymbol{U}^z\boldsymbol{h}_v^{(l)}\right), \tag{12}$$

$$\boldsymbol{r}_v^{(l+1)}=\sigma\left(\boldsymbol{W}^r\boldsymbol{h}_{N_v}^{(l+1)}+\boldsymbol{U}^r\boldsymbol{h}_v^{(l)}\right), \tag{13}$$

$$\tilde{\boldsymbol{h}}_v^{(l+1)}=\tanh\left(\boldsymbol{W}\boldsymbol{h}_{N_v}^{(l+1)}+\boldsymbol{U}\left(\boldsymbol{r}_v^{(l+1)}\odot\boldsymbol{h}_v^{(l)}\right)\right), \tag{14}$$

$$\boldsymbol{h}_v^{(l+1)}=\left(1-\boldsymbol{z}_v^{(l+1)}\right)\odot\boldsymbol{h}_v^{(l)}+\boldsymbol{z}_v^{(l+1)}\odot\tilde{\boldsymbol{h}}_v^{(l+1)}, \tag{15}$$

其中$\boldsymbol{W}^z$, $\boldsymbol{U}^z$, $\boldsymbol{W}^r$, $\boldsymbol{U}^r$, $\boldsymbol{W}$, $\boldsymbol{U}$为可训练参数矩阵, $\odot$为 Hadamard 积, σ是非线性激活函数.

2)Readout 层

Readout 层则通过聚合学习资源-学习行为图中所有节点的向量表征,得到学习者的各粒度兴趣向量. 具体聚合公式如式(16)所示.

$$\boldsymbol{h}_G=\sum_{i\in V}\alpha_i\boldsymbol{e}_{v_i}^{(l)}, \tag{16}$$

其中V表示学习资源-学习行为图中的节点集合, $\boldsymbol{e}_{v_i}^{(l)}$是图中第$i$个节点在第$l$层的表征向量, α_i为第i个节点的权重,具体计算公式如式(17)所示.

$$\alpha_i=softmax(\boldsymbol{q}^{\mathrm{T}}\sigma(\boldsymbol{W}_1\boldsymbol{e}_i^{(l)}+\boldsymbol{W}_2\boldsymbol{e}_{\mathrm{last}}^{(l)}+\boldsymbol{r})), \tag{17}$$

其中$\boldsymbol{q}$和$\boldsymbol{r}\in\mathbb{R}^d$是参数矩阵, $\boldsymbol{W}_1$和$\boldsymbol{W}_2\in\mathbb{R}^{d\times d}$是参数矩阵, $\boldsymbol{e}_{\mathrm{last}}^{(l)}$是学习者历史行为序列最后交互的学习资源在第$l$层的表征向量.

将学习者各粒度的历史行为序列输入至学习资源关系增强的学习者兴趣表征层,可获得学习资源关系增强的学习者近期课程内兴趣向量$\boldsymbol{e}'_{u2l_2}$、中期跨课程兴趣向量$\boldsymbol{e}''_{u2l_2}$和长期跨课程兴趣向量$\boldsymbol{e}_{u2g_2}$.

第 3 步,时空多粒度兴趣模式提取. 通过学习资源关系增强的学习者兴趣表征层获得增强后的学习者近期课程内兴趣向量、中期跨课程兴趣向量和长期跨课程兴趣向量后,通过平均池化层聚合对应粒度兴趣向量,得到最终学习者近期课程内兴趣向量$\boldsymbol{e}'_{u2l}$、中期跨课程兴趣向量$\boldsymbol{e}''_{u2l}$和长期跨课程兴趣向量$\boldsymbol{e}_{u2g}$. 以学习者近期课程内的兴趣偏好为例,计算公式如式(18)所示,其他兴趣向量以此类推.

$$\boldsymbol{e}'_{u2l}=mean_pooling(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}'_{u2l_2}). \tag{18}$$

第 4 步. 时空多粒度兴趣自监督任务. 由于时空多粒度兴趣缺少可靠的监督信号,本文设计了多粒度兴趣自监督任务,以学习者近期课程内兴趣向量为例,约束条件如式(19)所示,使用 BPR 损失函数对学习者近期课程内兴趣向量、中期跨课程兴趣向量和长期跨课程兴趣向量均进行自监督约束.

$$\begin{cases}sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}'_{u2l_2})>sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}''_{u2l_1}),\\ sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}'_{u2l_2})>sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}_{u2l_{g_1}}),\\ sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}'_{u2l_2})>sim(\boldsymbol{e}'_{u2l_2},\boldsymbol{e}''_{u2l_2}),\\ sim(\boldsymbol{e}'_{u2l_1},\boldsymbol{e}'_{u2l_2})>sim(\boldsymbol{e}'_{u2l_2},\boldsymbol{e}_{u2l_{g_2}}),\end{cases} \tag{19}$$

其中sim是向量相似度度量函数,本文的实现方式是内积.

2.4 学习资源推荐模块

该模块旨在自适应地融合学习者在学习空间和时间维度的多粒度兴趣向量,在此基础上为学习者推荐学习资源. 学习者在学习空间多粒度兴趣的融合方法如式(20)所示,可获得融合后的兴趣向量$\boldsymbol{e}_{\mathrm{space}}$,同理可得学习者在时间维度的多粒度兴趣融合向量$\boldsymbol{e}_{\mathrm{time}}$.

$$\boldsymbol{e}_{\mathrm{space}}=\sum_{i=1}^{5}\alpha_i\boldsymbol{e}_{\mathrm{space}_i}, \tag{20}$$

其中$\boldsymbol{e}_{\mathrm{space}_i}$是学习者在学习空间的第$i$个兴趣向量, α_i的计算公式如式(21)所示.

$$\alpha_i=\frac{\exp(\omega_i)}{\sum_{j=1}^{5}\exp(\omega_j)}, \tag{21}$$

其中ω_i的计算公式如式(22)所示. 由式(22)可知, ω_i可根据学习者和学习者最后交互的学习资源,自适应计算各粒度兴趣的权重.

$$\omega_i=\tau_1(\boldsymbol{e}'_u\|\boldsymbol{e}_{\mathrm{space}_i}\|(\boldsymbol{e}'_u-\boldsymbol{e}_{\mathrm{space}_i})\|(\boldsymbol{e}'_u\times\boldsymbol{e}_{\mathrm{space}_i})\|\boldsymbol{e}_{\mathrm{last}}), \tag{22}$$

其中τ_1是深度神经网络,如式(23)所示. $\boldsymbol{e}_{\mathrm{last}t}$是学习者最后一次交互的学习资源表征向量,即历史行为序列中最后一个学习资源的嵌入表征, $\boldsymbol{e}'_u$是学习空间多粒度兴趣建模模块中的用户表征,由学习空间各兴趣向量聚合得到, $\|$是向量拼接操作.

$$\boldsymbol{y}=\sigma(\boldsymbol{W}_2(LeakyReLU(\boldsymbol{W}_1\boldsymbol{x}+\boldsymbol{b}_1))+\boldsymbol{b}_2), \tag{23}$$

其中$\boldsymbol{x}$, $\boldsymbol{y}$分别为τ_1的输入和输出, $\boldsymbol{W}_1$, $\boldsymbol{W}_2$为权值矩阵, $\boldsymbol{b}_1$, $\boldsymbol{b}_2$为偏置向量, $LeakyReLU$是激活函数, σ是 sigmoid 激活函数.

学习者最终表征向量$\boldsymbol{e}_u$的计算公式如式(24)所示.

$$\boldsymbol{e}_u=\tau_2(\boldsymbol{e}'_u\|\boldsymbol{e}_{\mathrm{space}}\|\boldsymbol{e}_{\mathrm{time}}\|\boldsymbol{e}_{\mathrm{last}}), \tag{24}$$

其中τ_2是深度神经网络,通过单层全连接层实现.

基于上述步骤得到学习者表征向量和学习资源表征向量后,计算学习者对候选学习资源的偏好评

分，将排名靠前的学习资源推荐给学习者. 偏好评分计算公式如式(25)~(27)所示.

$$\hat{\boldsymbol{y}} = (\hat{y}_1, \hat{y}_2, \cdots, \hat{y}_{|V|}), \tag{25}$$

$$\hat{y}_i = \frac{\exp(s_i)}{\sum_{j=1}^{|V|}\exp(s_j)}, \tag{26}$$

$$s_i = \boldsymbol{e}_u \boldsymbol{e}_{v_i}^{\mathrm{T}}, \tag{27}$$

其中$\hat{\boldsymbol{y}} \in \mathbb{R}^{1\times|V|}$是学习者$u$对所有候选学习资源的偏好评分向量，$\hat{y}_i$是学习者对第$i$个学习资源的归一化后偏好得分，$s_i$是学习者对第$i$个学习资源的归一化前偏好得分，$\boldsymbol{e}_{v_i}$是经过嵌入层后的学习资源表征向量，计算公式如式(6)所示.

最后，选取得分最高的N个学习资源组成推荐列表，具体计算公式如式(28)所示.

$$rec_list = TopN(\hat{\boldsymbol{y}}). \tag{28}$$

本文使用的损失函数是交叉熵损失函数，其计算公式如式(29)所示.

$$L = L_{\mathrm{main}} + \lambda_1 L_{\mathrm{bpr}} + \lambda_2 \|\Theta\|_2^2, \tag{29}$$

其中L_{main}是交叉熵损失，L_{bpr}是BPR损失函数，Θ是模型参数，λ_1和λ_2是权重超参.

3 实验与结果

3.1 数据集

本文实验所用学堂在线平台MOOCCube数据集的统计信息如表4所示，头歌实践教学平台MOOPer数据集的统计信息如表5所示.

Table 4 Statistical Information for MOOCCube Dataset

表4 MOOCCube数据集统计信息

实体名	数量	关系名	数量
学习者	1 713	学习者-学习资源交互	126 131
课程	14	课程-学习资源	1 548
学习资源	1 202	学习资源-知识点	3 925
知识点	490	课程-知识点	1 259
教师	19	知识点-知识点	730
学校	5	教师-课程	34

3.2 评价指标

本文使用推荐中常用的召回率(recall ratio, *Recall*)指标和归一化折损累计增益(normalized discounted cumulative gain, *NDCG*)指标来衡量实验效果.

*Recall*的计算公式如(30)所示.

$$Recall@K = \frac{N_{hits@K}}{N}, \tag{30}$$

Table 5 Statistical Information for MOOPer Dataset

表5 MOOPer数据集统计信息

实体名	数量	关系名	数量
学习者	44 523	学习者-学习资源交互	641 744
知识点	1 267	二级学科-学习资源	2 625
学习资源	1 127	学习资源-知识点	1 853
二级学科	58	学习资源-教师	1 127
一级学科	13	一级学科-二级学科	58
教师	142	教师-学校	142
学校	46	学习者-学校	44 523

其中K是从推荐列表中取评分较大学习资源的个数，N是测试集中学习者数量，$N_{hits@K}$是学习者在测试集中交互的学习资源出现在Top$K$推荐列表的次数.

*NDCG*可衡量推荐算法的排序能力，其计算公式如(31)所示.

$$NDCG@K = \frac{DCG@K}{IDCG@K} = \frac{\sum_{i=1}^{K}\frac{2^{rel_i}-1}{\mathrm{lb}(i+1)}}{\sum_{i=1}^{REL_K}\frac{2^{rel_i}-1}{\mathrm{lb}(i+1)}}, \tag{31}$$

其中*DCG*是折损累积增益，相关物品排名越靠前，*DCG*的值越大，*IDCG*是理想状态的*DCG*，即相关的物品排在最前面，*rel*是相关性分数.

3.3 参数设置

为保证实验的公平性，本文所有实验使用相同的方式划分训练集和测试集. 本文模型的迭代次数设置为1 000个轮次，在模型训练的过程中，引入了早停机制以防止模型过拟合，具体设置为：当评测指标在15个周期内连续下降时，模型的训练将停止. 数据训练批次大小(batch size)设置为1 024，优化器为Adam，学习率为0.001.嵌入向量维度为64，GNN网络层数为3，节点采样率为0.9，损失函数中的λ_1设置为0.2，λ_2设置为0.02，在MOOCCube数据集上，训练集与测试集比例为0.9，在MOOPer数据集上该比例为0.7.

3.4 对照方法

本文将所提出方法与以下方法进行对比：

GRU4Rec[36]使用多层GRU来捕捉用户历史行为序列中的序列信息，是序列推荐中的经典算法.

Caser[37]使用CNN从用户短期历史行为序列中提取用户的短期兴趣，该算法更注重用户短期兴趣的记忆.

STAMP[38]提出一种短期注意力/记忆优先的会话推荐算法，该算法从会话上下文的长期记忆中捕获用户的一般兴趣，同时从短期记忆中提取用户的当前兴趣. 因此，该算法可同时捕捉用户的长短期兴

趣，且对用户兴趣漂移更敏感.

NextItNet[39]算法借鉴了 pixelCNN 的思想，采用层叠的 1 维空洞卷积扩大感受野来提取物品序列特征，引入了残差的学习机制来防止梯度消失的问题，且在降维和升维时，使用 1×1 卷积核以减少模型参数.

SDAE[20]将深度协同过滤组件与宽线性组件结合，在利用学习者和学习资源特征的基础上，引入学习资源的其他特征(如难度、类型和知识点)进行混合推荐.

SRGNN[35]是基于图神经网络的会话推荐算法，该算法使用用户的历史会话构建会话图，在此基础上，使用 GGNN 学习会话图中物品的表征向量，然后获得每个会话的表征向量为用户推荐.

BERT4Rec[4]算法将自然语言处理中的 BERT 模型引入到推荐领域，该算法采用深层双向自注意力机制建模用户的历史行为序列，为避免信息泄露并有效训练双向模型，提出 Cloze 目标的方式进行序列推荐，即通过联合物品左右的上下文来预测序列中随机 mask 的物品.

LSTMCQP[13]是基于长短期记忆网络的一种知识追踪算法，该模型嵌入了知识组件的上下文，实现了知识的上下文表示，更准确地预测出学习者的知识状态，从而进行相关知识的练习推荐.

GCSAN[40]提出一种基于图上下文自注意力网络的会话推荐，该算法首先将用户历史会话中的物品序列构建为会话图，在此基础上，使用自注意力网络捕捉用户历史行为序列中的全局依赖关系，使用 GGNN 捕捉用户历史行为序列中的局部依赖关系.

LightSANs[41]算法指出被广泛应用于序列推荐的自注意力机制，存在复杂度较高且过度参数化的问题，对此，该算法提出将用户历史交互过的物品分类为不超过 k 类，将每一类视为一个潜在兴趣，将用户历史行为中的物品和 k 个潜在兴趣做交互，从而避免了物品之间的交互，有效减少了模型参数.

CORE[42]算法指出非线性编码学习得到的每个会话的嵌入向量和物品的嵌入向量不在同一表征空间，影响推荐效果. 该算法提出移除物品嵌入向量上的非线性激活函数，并将会话的嵌入向量编码为物品嵌入向量的线性组合，进而缓解会话和物品表征不一致的问题.

MSGIFS[33]算法是基于多粒度兴趣建模的推荐算法，将用户历史会话所交互的物品序列切分为多个不同长度的序列片段，将这些片段作为用户不同粒度的兴趣单元，结合所构建的会话图，使用注意力机制，聚合不同粒度兴趣单元的表征向量，得到用户不同粒度的兴趣表征向量.

HinCRec[43]算法将学习空间中用户、课程、视频和知识点构建为异构信息网络，并用注意力图神经网络进行建模，从而得到学习者和学习资源的表征向量. 其次，该模型使用强化学习策略根据用户和知识点之间的动态交互，提供多样化推荐.

3.5 实验结果及分析

3.5.1 整体性能及分析

MGIRec 算法和所选对照组算法的实验结果如表 6 所示. 实验结果表明，本文所提 MGIRec 算法在 MOOCCube 和 MOOPer 数据集上的效果均优于所选对照组算法；GRU4Rec 作为序列推荐的经典算法，取得了不错的效果；SRGNN 效果明显优于 STAMP，GRU4Rec 算法，表明使用图神经网络刻画学习者复杂的历史行为关系的有效性；LightSANs 算法显著优于 SRGNN 算法，显示出对序列推荐的自注意力机制优化和 decoupled 位置编码的有效性；HinCRec 算法为最优对照算法，验证了学习空间异构信息网络构建的必要性以及知识点强化学习的有效性. 在 MOOCCube 数据集上，MGIRec 算法在 *Recall*@10，*Recall*@20，*NDCG*@10，*NDCG*@20 指标上相比最优对照组算法平均提升了 4% 左右，在 MOOPer 数据集上平均提升了 5% 左右，可见 MGIRec 算法分别从学习空间和时间维度提取学习者多粒度的兴趣表征，更准确建模了学习者的兴趣偏好.

3.5.2 MGIRec 算法的消融实验结果及分析

为了验证本文所提方法的有效性，完成了 4 个消融实验，分别为时空各粒度兴趣建模消融实验、基于课程偏好的切分方法消融实验、学习资源关系增强的学习者兴趣表征消融实验和时空多粒度兴趣自监督任务消融实验.

1)时空各粒度兴趣建模消融实验

为验证 MGIRec 算法中时空各粒度兴趣偏好建模是否有效提升推荐效果，设计了以下消融实验：

①$\text{MGIRec}_{\text{w/o_s}}$. 去除学习空间多粒度兴趣表征建模.

②$\text{MGIRec}_{\text{w/o_l}'}$. 去除学习者近期课程内的部兴趣偏好建模.

③$\text{MGIRec}_{\text{w/o_l}'\&l''}$. 去除学习者近期课程内、中期跨课程兴趣偏好建模.

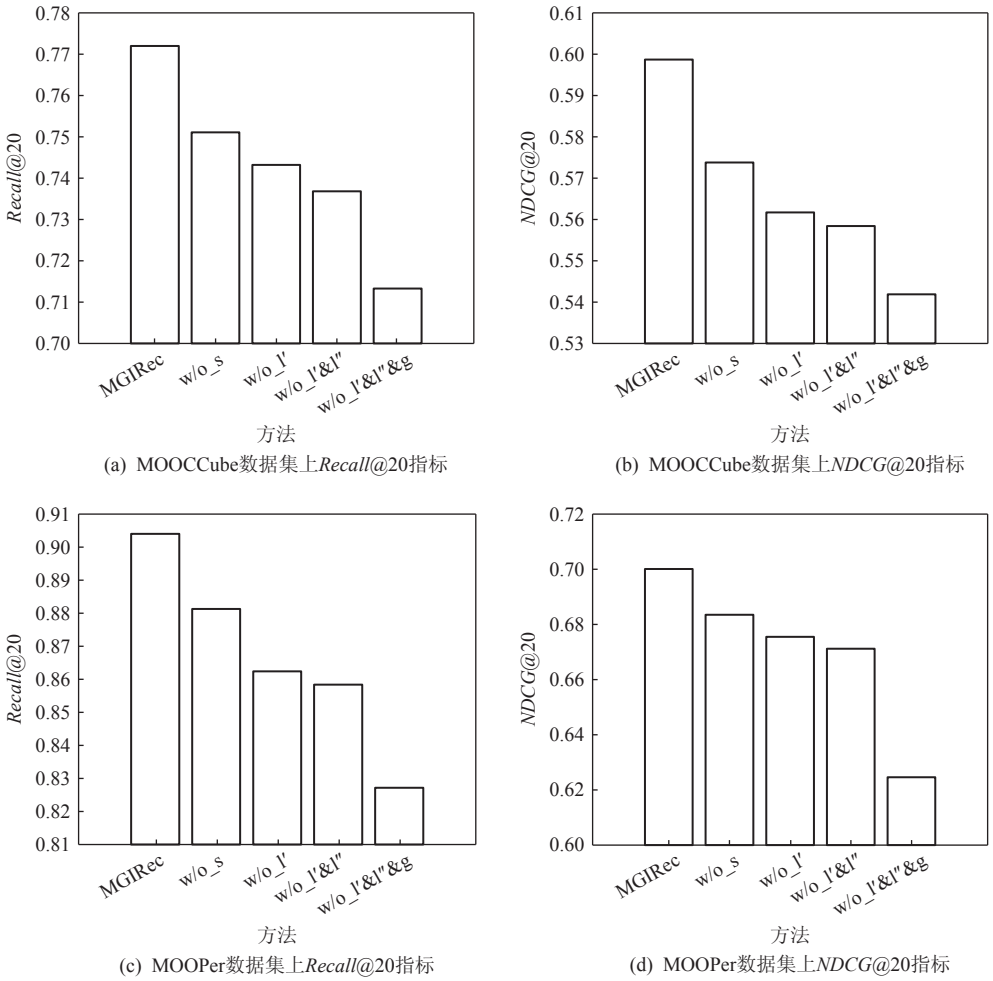
④$\text{MGIRec}_{\text{w/o_l}'\&l''\&g}$. 去除学习者在时空中所有粒度兴趣偏好建模.

如图 7 所示，时空各粒度兴趣建模消融实验结果

Table 6 Recommendation Effectiveness of MGIRec Algorithm on MOOCCube and MOOPer Datasets

表 6 MOOCCube 和 MOOPer 数据集下 MGIRec 算法推荐效果

方法	MOOCCube				MOOPer			
	Recall@10	*Recall*@20	*NDCG*@10	*NDCG*@20	*Recall*@10	*Recall*@20	*NDCG*@10	*NDCG*@20
NextItNet	0.567 4	0.640 4	0.418 3	0.436 7	0.677 1	0.775 0	0.466 8	0.491 7
Caser	0.603 0	0.671 3	0.469 9	0.487 2	0.641 3	0.769 2	0.414 8	0.447 4
GRU4Rec	0.633 4	0.689 4	0.491 6	0.505 7	0.738 9	0.826 6	0.538 6	0.561 0
STAMP	0.636 9	0.689 4	0.515 7	0.528 9	0.702 5	0.790 8	0.517 2	0.539 6
SDAE	0.637 8	0.700 1	0.526 7	0.538 7	0.725 0	0.797 5	0.536 1	0.571 1
SRGNN	0.651 5	0.699 4	0.530 8	0.542 9	0.773 2	0.839 9	0.614 6	0.631 6
BERT4Rec	0.664 3	0.722 1	0.539 8	0.554 4	0.711 3	0.817 9	0.512 4	0.539 5
LSTMCQP	0.658 7	0.719 9	0.536 3	0.549 6	0.703 7	0.809 6	0.503 5	0.534 4
CORE	0.662 6	0.729 1	0.524 9	0.544 1	0.677 6	0.813 0	0.514 1	0.538 6
GCSAN	0.674 3	0.725 6	0.536 6	0.549 7	0.789 4	0.850 4	0.626 6	0.642 2
MSGIFSR	0.680 9	0.736 4	0.523 3	0.539 5	0.773 6	0.848 7	0.617 3	0.637 5
LightSANs	0.681 3	0.736 7	0.526 7	0.540 7	0.746 9	0.839 6	0.516 1	0.539 8
HinCRec	0.704 6	0.748 6	0.542 1	0.557 2	0.792 5	0.862 0	0.639 3	0.654 1
MGIRec（本文）	0.717 8	0.772 0	0.566 4	0.598 7	0.835 3	0.904 0	0.662 7	0.700 1
提升/%	1.61	3.13	4.48	7.45	5.40	4.87	3.66	7.03



(a) MOOCCube数据集上*Recall*@20指标 (b) MOOCCube数据集上*NDCG*@20指标

(c) MOOPer数据集上*Recall*@20指标 (d) MOOPer数据集上*NDCG*@20指标

Fig. 7 Experimental results of the ablation study on interest modeling at different granularities in spatio-temporal domain

图 7 时空各粒度兴趣建模消融实验结果

表明，MGIRec 算法中时空各粒度兴趣偏好建模均有效，其中学习者近期课程内的局部兴趣和长期跨课程兴趣偏好建模的效果最好，学习空间多粒度兴趣表征对算法的提升也有显著促进效果. 分析原因在于学习者习惯集中学习一门课程内的多个学习资源，且学习者在选择学习资源时，受其长期兴趣的影响.

2）基于课程偏好的切分方法消融实验

为验证 MGIRec 算法中基于课程偏好的切分方法是否能有效提升推荐效果，本文对切分方法中不同步骤进行拆分，设计了以下消融和对照实验.

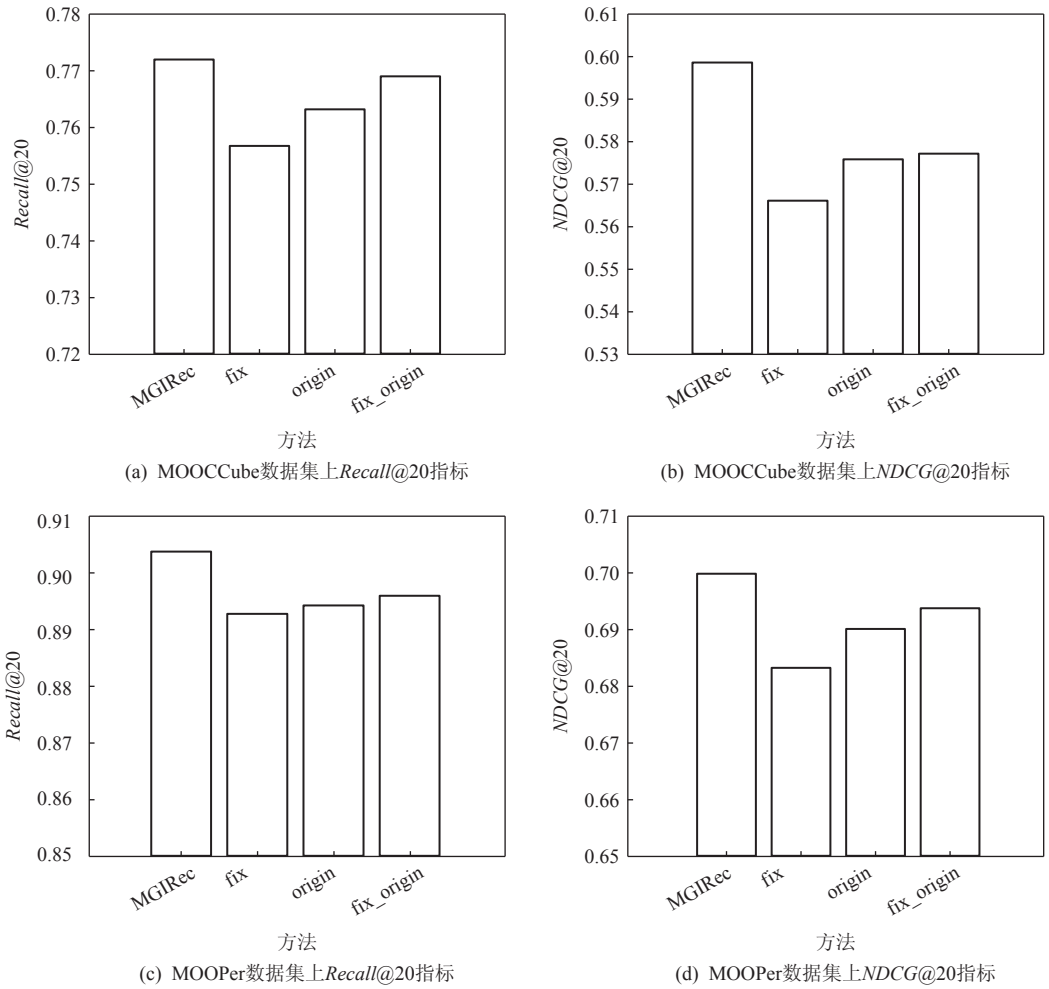
①fix. 直接将近期区间作为近期历史行为序列，中期区间作为中期历史行为序列，即不考虑用户的课程偏好.

②origin. 在划分学习者近期课程内历史行为序列时，将用户最后 1 次点击资源的隶属课程作为近期偏好课程，然后找到学习者第 1 次学习目标课程下的学习资源，以此作为序列切分的左边界；同理，在切分中期跨课程历史行为序列时，将上述近期课程内序列的前 1 个学习资源所属课程作为目标课程，找到学习者第 1 次学习该课程内的学习资源，以此作为序列切分的左边界.

③fix_origin. 在近期区间和中期区间内使用 origin 方法进行切分，分别得到近期和中期历史行为序列.

如图 8 所示，实验结果表明，fix 切割方式取得最差的表现，origin 方法取得的表现要优于 fix.由于 fix 方法直接用时间维度上的固定区间代表用户近期偏好和中期偏好，忽略了序列中的课程信息，因此可以验证 origin 方法中按课程切分序列的有效性. 然而 origin 方法存在 2 个问题：其一是特殊情况问题，若用户最后 1 次点击的资源隶属课程在序列较早的位置就出现了，将一个时间跨度较大的序列作为用户近期课程内历史行为序列显然是不合理的；其二是用户最后 1 次点击的课程也不一定能代表用户当前的课程好，用其作为边界切分不合理，可能导致序列偏好获取不准确（例如误触）.

可以看到 fix_origin 方法的表现要优于 origin 方



(a) MOOCCube数据集上*Recall*@20指标 (b) MOOCCube数据集上*NDCG*@20指标

(c) MOOPer数据集上*Recall*@20指标 (d) MOOPer数据集上*NDCG*@20指标

Fig. 8 Experimental results of the ablation study on course preference based cutting method

图 8 基于课程偏好的切分方法消融实验结果

法，其通过限制切分的左边界解决了 origin 方法中存在的第 1 个问题. 本文使用的基于课程偏好的切分方法取得了最好的表现，其通过限制边界以及百分比的方法，同时解决了 origin 方法中存在的 2 个问题，更好地表达用户的近期和中期偏好.

3)学习资源关系增强的学习者兴趣表征消融实验

为验证 GRU 层、学习资源关系增强的学习者兴趣表征方法是否有作用，对 MGIRec 算法中的 GRU 层和学习资源关系增强的学习者兴趣表征层进行拆分，设计了以下实验.

①$\text{MGIRec}_{\text{w/o_gru}}$. 去除 GRU 层对用户兴趣偏好的建模，即只使用学习资源关系增强的学习者兴趣表征层建模学习者的兴趣.

②$\text{MGIRec}_{\text{w/o_enh}}$. 去除学习资源关系增强的学习者兴趣表征层，即只使用 GRU 层建模学习者的兴趣.

如图 9 所示，学习资源关系增强的学习者兴趣表征消融实验结果表明，学习资源关系增强的学习者兴趣表征方法可有效提升推荐效果.

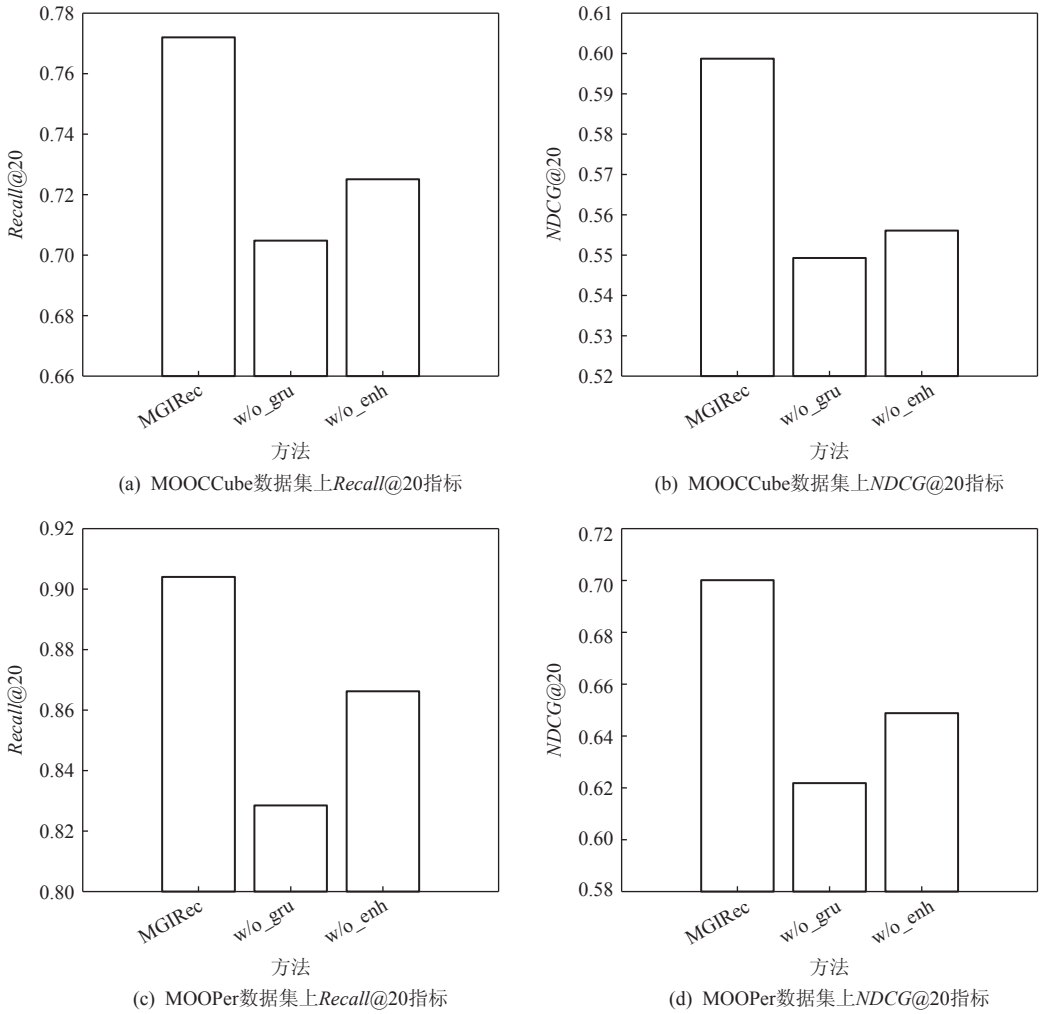
4)时空多粒度兴趣自监督任务消融实验

为验证多粒度兴趣自监督任务是否有助于提升推荐效果，并对自监督损失函数的超参数 λ_1 在 [0,1] 内进行敏感性探究，进行了以下消融实验，其中，当 $\lambda_1 = 0$ 时即为去除了自监督任务.

如图 10 所示，可以看到多粒度兴趣自监督任务的引入显著提升了模型的推荐效果，且超参数 λ_1 对推荐效果影响较大，具体表现为指标上先增加后减小，当 $\lambda_1 = 0.2$ 时模型在 2 个数据集上取得了最好的表现. 在初始随着 λ_1 的增大，对于各类表征的约束作用逐渐显著，使得表征更准确，但后续 λ_1 持续增大会影响主损失函数 L_{main} 的权重，导致性能下降.

3.5.3 多粒度贡献度可视化与分析

为了直观地展示各粒度在时间和空间维度上的贡献度，本文采用 t-SNE[44] 技术将各粒度的多维嵌入



(a) MOOCCube数据集上*Recall*@20指标　(b) MOOCCube数据集上*NDCG*@20指标

(c) MOOPer数据集上*Recall*@20指标　(d) MOOPer数据集上*NDCG*@20指标

Fig. 9 Experimental results of the ablation study on learner interest representation with enhanced learning resource relations

图 9 学习资源关系增强的学习者兴趣表征消融实验结果

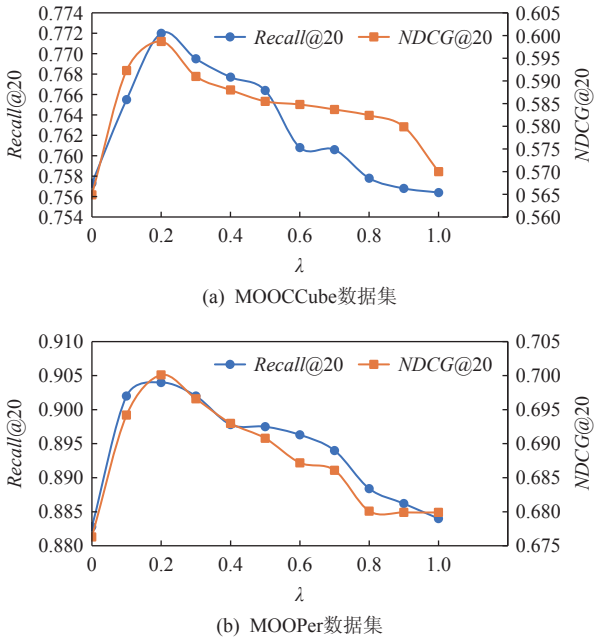


Fig. 10 Experimental results of the ablation study on multi-granularity interest self-supervised tasks

图 10 多粒度兴趣自监督任务消融实验结果

向量在 2 维空间中可视化. 本文从 MOOPer 数据集中随机选取了 100 位学习者的学习序列作为输入, 在空间维度下, 提取知识点粒度兴趣向量、学习资源粒度兴趣向量、课程粒度兴趣向量、其他(教师和学校)粒度兴趣向量和学习者在空间维度的多粒度兴趣融合向量; 在时间维度下, 提取近期课程内兴趣向量、中期跨课程兴趣向量、长期跨课程兴趣向量和学习者在时间维度的多粒度兴趣融合向量. 对所提取的各粒度向量在空间和时间维度下分别绘制了散点图, 如图 11 所示. 其中每个点代表对应粒度兴趣向量在 2 维空间中的表示, 通过比较各粒度兴趣向量与多粒度兴趣融合向量间的距离可以直观地展示各类粒度的贡献度: 距离越近, 贡献度越高. 在空间维度下, 如图 11(a)所示, 学习资源、知识点和课程对算法贡献度较高, 且课程和知识点的贡献度在不同学习者上差异较明显, 说明学习者受课程、知识点的影响较大; 在时间维度下, 如图 11(b)所示, 各类粒度的贡献度较为平均, 说明时间维度下各粒度兴趣均对最终的结果有着正向的贡献.

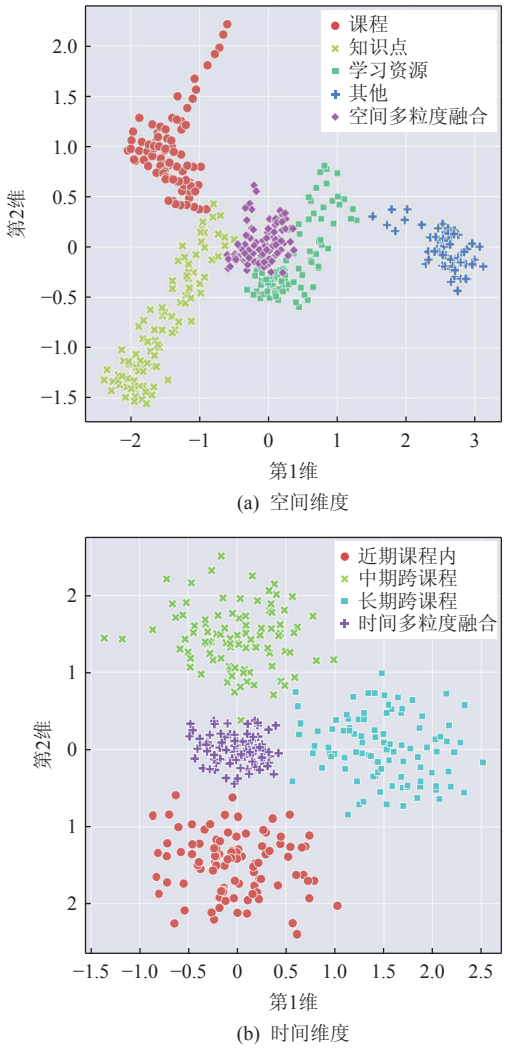


Fig. 11 Diagram of multi-granularity contribution visualization

图 11 多粒度贡献度可视化图

Table 7 Impact of the Number of GNN Network Layers on Model in MOOCCube and MOOPer Datasets

表 7 MOOCCube 和 MOOPer 数据集下 GNN 网络层数对模型的影响

GNN 网络层数	MOOCCube		MOOPer	
	Recall@20	*NDCG*@20	*Recall*@20	*NDCG*@20
1	0.741 4	0.551 2	0.871 9	0.675 3
2	0.757 7	0.568 6	0.882 5	0.683 9
3	**0.772 0**	**0.598 7**	**0.904 0**	**0.700 1**
4	0.748 1	0.557 3	0.878 6	0.682 1
5	0.725 8	0.530 5	0.841 7	0.649 3

注: 黑体数值表示最优值.

3.5.4 MGIRec 算法超参数敏感性实验与分析

GNN 网络层数是影响图表征学习效果的重要因素, 它在某种程度上决定了各节点最终向量的信息来源, 本文设置网络层数 1~5 以探索其影响. 实验结果如表 7 所示, 结果表明 GNN 网络层数对推荐效果影响较大, 具体表现为各指标先增加后减小, 在层数为 3 时达到峰值. 在初始随着层数的增加, 图神经网络中节点可以聚合的邻居范围更大, 使得节点的表征更准确, 但后续的层数继续增加, 会使得图中节点

的表征过平滑，进而推荐效果下降.

4 总结与展望

本文针对学习者在线学习场景，提出基于时空多粒度兴趣建模的学习资源推荐方法，解决学习资源推荐中的学习兴趣难表征、兴趣模式难发现的问题. 该方法的特色在于设计并实现了一种融合学习空间和时间维度的学习兴趣表征学习架构，不但在知识点、学习资源、课程等多个学习空间粒度上表征学习者兴趣，并引入虚拟节点防止噪声信息. 在时间维度上，表征并挖掘学习者近期课程内、中期跨课程和长期跨课程的多粒度的兴趣模式，进而通过多粒度兴趣自适应融合层将学习者在学习空间和时间2个维度上融合，破解了学习者兴趣复杂多样难表征和兴趣模式动态变化难捕获的问题. 并且在时空多粒度兴趣提取过程中，本文设计多粒度兴趣自监督任务显式区分不同粒度的兴趣向量，进一步提高推荐学习资源的准确性. 本文的研究为充分提取学习者兴趣和挖掘学习兴趣模式以及提高学习资源推荐效果提供了参考和借鉴. 下一步将考虑结合学习空间的结构信息，引入因果图挖掘用户交互序列中的因果信息，以提升资源推荐的可解释性.

作者贡献声明：朱海萍、刘均、田锋提出算法思路和实验方案，参与论文撰写和修改；王子瑜、赵成成负责完成实验、实验结果分析及论文撰写；陈妍提出论文修改意见.

参 考 文 献

[1] da Silva F L, Slodkowski B K, da Silva K K A, et al. A systematic literature review on educational recommender systems for teaching and learning: Research trends, limitations and opportunities[J]. Education and Information Technologies, 2023, 28(3): 3289−3328

[2] Lin Yuanguo, Lin Fan, Zeng Wenhua, et al. Hierarchical reinforcement learning with dynamic recurrent mechanism for course recommendation[J]. Knowledge-Based Systems, 2022, 244(5): 1−15

[3] Chen Qiwei, Zhao Huan, Li Wei, et al. Behavior sequence transformer for e-commerce recommendation in Alibaba[C/OL]//Proc of the 1st Int Workshop on Deep Learning Practice for High-Dimensional Sparse Data (KDD). New York: ACM, 2019 [2024-09-09]. https://doi.org/10.1145/3326937.3341261

[4] Sun Fei, Liu Jun, Wu Jian, et al. BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer[C]//Proc of the 28th ACM Int Conf on Information and Knowledge Management (CIKM). New York: ACM, 2019: 1441−1450

[5] Chen Biyi, Huang Lin, Wang Changdong, et al. Explicit and implicit feedback based collaborative filtering algorithm[J]. Journal of Software, 2020, 31(3): 794−805 (in Chinese)
(陈碧毅, 黄玲, 王昌栋, 等. 融合显式反馈与隐式反馈的协同过滤推荐算法[J]. 软件学报, 2020, 31(3): 794−805)

[6] Zheng Yu, Gao Chen, Chang Jianxin, et al. Disentangling long and short-term interests for recommendation[C]//Proc of the ACM Web Conf 2022(WWW). New York: ACM, 2022: 2256−2267

[7] Li Chao, Liu Zhiyuan, Wu Mengmeng, et al. Multi-interest network with dynamic routing for recommendation at Tmall[C]//Proc of the 28th ACM Int Conf on Information and Knowledge Management (CIKM). New York: ACM, 2019: 2615−2623

[8] Xiao Zhibo, Yang Luwei, Jiang Wen, et al. Deep multi-interest network for click-through rate prediction[C]//Proc of the 29th ACM Int Conf on Information and Knowledge Management (CIKM). New York: ACM, 2020: 2265−2268

[9] Cen Yukuo, Zhang Jianwei, Zou Xu, et al. Controllable multi-interest framework for recommendation[C]//Proc of the 26th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining (KDD). New York: ACM, 2020: 2942−2951

[10] Guo Wei, Zhang Can, He Zhicheng, et al. Miss: Multi-interest self-supervised learning framework for click-through rate prediction[C]// Proc of the 38th Int Conf on Data Engineering. Piscataway, NJ: IEEE, 2022: 727−740

[11] Ai Fangzhe, Chen Yishuai, Guo Yuchun, et al. Concept-aware deep knowledge tracing and exercise recommendation in an online learning system[J/OL]. International Educational Data Mining Society, 2019[2024-09-09]. https://eric.ed.gov/?id=ED599194

[12] Huang Zhenya, Liu Qi, Zhai Chengxiang, et al. Exploring multi-objective exercise recommendations in online education systems[C]// Proc of the 28th ACM Int Conf on Information and Knowledge Management. New York: ACM, 2019: 1261−1270

[13] Huo Yujia, Wong D F, Ni L M, et al. Knowledge modeling via contextualized representations for LSTM-based personalized exercise recommendation[J]. Information Sciences, 2020, 523:266−278

[14] Wu Zhengyang, Li Ming, Tang Yong, et al. Exercise recommendation based on knowledge concept prediction[J]. Knowledge-Based Systems, 2020, 210: 106481

[15] Hu Yuanyuan, Jiang Wenjun, Ren Desheng, et al. Integrating user duitability and course matching degree for online course recommendation method[J]. Journal of Computer Research and Development, 2022, 59(11): 2520−2533 (in Chinese)
(胡园园, 姜文君, 任德盛, 等. 一种结合用户适合度和课程搭配度的在线课程推荐方法[J]. 计算机研究与发展, 2022, 59(11): 2520−2533)

[16] Ren Xinwei, Yang Wei, Jiang Xianliang, et al. A deep learning framework for multimodal course recommendation based on LSTM+ attention[J]. Sustainability, 2022, 14(5): 2907−2921

[17] Nafea SM, Siewe F, He Ying. On recommendation of learning objects using Felder-Silverman learning style model[J]. IEEE Access, 2019, 7: 163034−163048

[18] Wan Shanshan, Niu Zhendong. A learner oriented learning recommendation approach based on mixed concept mapping and immune algorithm[J]. Knowledge-Based Systems, 2016, 103: 28−40

[19] Yan Lingyao, Yin Chuantao, Chen Hui, et al. Learning resource recommendation in e-learning systems based on online learning style[C]//Proc of the 14th Int Conf on Knowledge Science, Engineering and Management (KSEM). New York: ACM, 2021: 373−385

[20] Gong Tuanji, Yao Xuanxia. Deep exercise recommendation model[J]. International Journal of Modeling and Optimization, 2019, 9(1): 18−23

[21] Liu Yu. A study on sequential recommendation of learning resources based on graph embedding[D]. Xi'an: Xi'an Jiaotong University, 2020 (in Chinese)
(刘雨. 基于图嵌入的学习资源序列推荐研究[D]. 西安：西安交通大学，2020)

[22] Gong Jibing, Wang Shen, Wang Jinlong, et al. Attentional graph convolutional networks for knowledge concept recommendation in moocs in a heterogeneous view[C]//Proc of the 43rd Int ACM SIGIR Conf on Research and Development in Information Retrieval (SIGIR). New York: ACM, 2020: 79−88

[23] Wang Xinhua, Jia Linzhao, Guo Lei, et al. Multi-aspect heterogeneous information network for MOOC knowledge concept recommendation [J]. Applied Intelligence, 2022, 53(9): 1−15

[24] Alatrash R, Chatti M A, Ain Q U, et al. ConceptGCN: Knowledge concept recommendation in MOOCs based on knowledge graph convolutional networks and SBERT[J]. Computers and Education: Artificial Intelligence, 2024, 6: 100193

[25] Zhang Huanyu, Shen Xiaoxuan, Yi Baolin, et al. KGAN: Knowledge grouping aggregation network for course recommendation in MOOCs[J]. Expert Systems with Applications, 2023, 211: 118344

[26] Chen Xin, Sun Yuhong, Zhou Tong, et al. A method on online learning video recommendation method based on knowledge graph[C/OL]//Proc of the 12th Int Conf on Intelligent Information Processing(IIP). 2022: 419−430. [2024-09-09]. https://link.springer.com/chapter/10.1007/978-3-031-03948-5_34#citeas

[27] Zhou Guorui, Zhu Xiaoqiang, Song Chenru, et al. Deep interest network for click-through rate prediction[C]//Proc of the 24th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining(KDD). New York: ACM, 2018: 1059−1068

[28] Zhou Guorui, Mou Na, Fan Ying, et al. Deep interest evolution network for click-through rate prediction[C]//Proc of the 33rd AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2019: 5941−5948

[29] Cao Yixin, Wang Xiang, He Xiangnan, et al. Unifying knowledge graph learning and recommendation: Towards a better understanding of user preferences[C]//Proc of the Web Conf 2019(WWW). New York: ACM, 2019: 151−161

[30] Wang Xiang, Jin Hongye, Zhang An, et al. Disentangled graph collaborative filtering[C]//Proc of the 43rd Int ACM SIGIR Conf on Research and Development in Information Retrieval (SIGIR). New York: ACM, 2020: 1001−1010

[31] Wang Xiang, Huang Tinglin, Wang Dingxian, et al. Learning intents behind interactions with knowledge graph for recommendation [C]//Proc of the Web Conf 2021(WWW). New York: ACM, 2021: 878−887

[32] Qi Tao, Wu Fangzhao, Wu Chuhan, et al. HieRec: Hierarchical user interest modeling for personalized news recommendation[C]// Proc of the 59th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA: ACL, 2021: 5446−5456

[33] Guo Jiayan, Yang Yaming, Song Xiangchen, et al. Learning multi-granularity consecutive user intent unit for session-based recommendation[C]//Proc of the 15th ACM Int Conf on Web Search and Data Mining (WSDM). New York: ACM, 2022: 343−352

[34] Jiang Lu, Liu Kunpeng, Wang Yibin, et al. Reinforced explainable knowledge concept recommendation in MOOCs[J]. ACM Transactions on Intelligent Systems and Technology, 2023, 14(3): 1−20

[35] Wu Shu, Tang Yuyuan, Zhu Yanqiao, et al. Session-based recommendation with graph neural networks[C]//Proc of the 33rd AAAI Conf on Artificial Intelligence. Palo Alto, CA: AAAI, 2019: 346−353

[36] Hidasi B, Karatzoglou A, Baltrunas L, et al. Session-based recommendations with recurrent neural networks[J]. arXiv preprint, arXiv: 1511.06939, 2016

[37] Tang Jiaxi, Wang Ke. Personalized top-n sequential recommendation via convolutional sequence embedding[C]//Proc of the 11th ACM Int Conf on Web Search and Data Mining. New York: ACM, 2018: 565−573

[38] Liu Qiao, Zeng Yifu, Mokhosi R, et al. STAMP: Short-term attention/memory priority model for session-based recommendation[C]// Proc of the 24th ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining (KDD). New York: ACM, 2018: 1831−1839

[39] Yuan Fajie, Karatzoglou A, Arapakis I, et al. A simple convolutional generative network for next item recommendation[C]//Proc of the 12th ACM Int Conf on Web Search and Data Mining. New York: ACM, 2019: 582−590

[40] Xu Chengfeng, Zhao Pengpeng, Liu Yanchi, et al. Graph contextualized self-attention network for session-based recommendation[C/OL]//Proc of the 28th Int Joint Conf on Artificial Intelligence. 2019: 3940−3946. [2024-09-09]. https://www.ijcai.org/proceedings/2019/0547.pdf

[41] Fan Xinyan, Liu Zheng, Lian Jianxun, et al. Lighter and better: Low-rank decomposed self-attention networks for next-item recommendation[C]//Proc of the 44th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2021: 1733−1737

[42] Hou Yupeng, Hu Binbin, Zhang Zhiqiang, et al. Core: Simple and effective session-based recommendation within consistent represen tation space[C]//Proc of the 45th Int ACM SIGIR Conf on Research and Development in Information Retrieval. New York: ACM, 2022: 1796−1801

[43] Gong Jibing, Wan Yao, Liu Ye, et al. Reinforced moocs concept recommendation in heterogeneous information networks[J]. ACM Transactions on the Web, 2023, 17(3): 1−27

[44] Van der Maaten L, Hinton G. Visualizing data using t-SNE[J/OL]. Journal of Machine Learning Research, 2008 [2024-09-09]. https://www.jmlr.org/papers/volume9/vandermaaten08a/vandermaaten08a.pdf?fbcl



Zhu Haiping, born in 1974. PhD, associate professor, PhD supervisor. Member of CCF. Her main research interests include big data analytics and recommender system.

朱海萍, 1974 年生. 博士, 副教授, 博士生导师. CCF 会员. 主要研究方向为大数据分析、推荐系统.



Wang Ziyu, born in 2000. Master candidate. His main research interests include recommender system and data mining.

王子瑜, 2000 年生. 硕士研究生. 主要研究方向为推荐系统、数据挖掘.



Zhao Chengcheng, born in 1997. Master. His main research interests include recommender system and data mining.

赵成成, 1997 年生. 硕士. 主要研究方向为推荐系统、数据挖掘.



Chen Yan, born in 1972. PhD, associate professor. Her main research interests include big data analytics, smart education, and artificial intelligence.

陈　妍, 1972 年生. 博士, 副教授. 主要研究方向为大数据分析、智慧教育、人工智能.



Liu Jun, born in 1973. PhD, professor, PhD supervisor. His main research interests include natural language understanding and computer vision.

刘　均, 1973 年生. 博士, 教授, 博士生导师. 主要研究方向为自然语言理解、计算机视觉.



Tian Feng, born in 1972. PhD, professor, PhD supervisor. His main research interests include artificial intelligence and smart education.

田　锋, 1972 年生. 博士, 教授, 博士生导师. 主要研究方向为人工智能、智慧教育.