

## 基于深度学习的个性化学习资源推荐综述

周洋涛, 褚华, 朱非非, 李祥铭, 韩子涵, 张帅

### 引用本文

周洋涛, 褚华, 朱非非, 李祥铭, 韩子涵, 张帅. [基于深度学习的个性化学习资源推荐综述](#)[J]. 计算机科学, 2024, 51(10): 17-32.

ZHOU Yangtao, CHU Hua, ZHU Feifei, LI Xiangming, HAN Zihan, ZHANG Shuai. [Survey on Deep Learning-based Personalized Learning Resource Recommendation](#) [J]. Computer Science, 2024, 51(10): 17-32.

---

## 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)

#### [基于近端线性组合的信号识别神经网络黑盒对抗攻击方法](#)

Black-box Adversarial Attack Methods on Modulation Recognition Neural Networks Based on Signal Proximal Linear Combination

计算机科学, 2024, 51(10): 425-431. <https://doi.org/10.11896/jsjcx.230900054>

#### [基于生成对抗网络的系统调用主机入侵检测技术](#)

System Call Host Intrusion Detection Technology Based on Generative Adversarial Network

计算机科学, 2024, 51(10): 408-415. <https://doi.org/10.11896/jsjcx.230700014>

#### [基于可见光-红外跨域迁移的红外弱小目标检测](#)

Infrared Dim and Small Target Detection Based on Cross-domain Migration of Visible Light and Infrared

计算机科学, 2024, 51(10): 287-294. <https://doi.org/10.11896/jsjcx.230800013>

#### [基于深度学习的病理切片质量控制算法综述](#)

Review of Quality Control Algorithms for Pathological Slides Based on Deep Learning

计算机科学, 2024, 51(10): 276-286. <https://doi.org/10.11896/jsjcx.231000167>

#### [基于深度学习的工业缺陷检测研究进展](#)

Research Progress in Industrial Defect Detection Based on Deep Learning

计算机科学, 2024, 51(10): 261-275. <https://doi.org/10.11896/jsjcx.230800158>

# 基于深度学习的个性化学习资源推荐综述

周洋涛 褚华 朱非非 李祥铭 韩子涵 张帅

西安电子科技大学计算机科学与技术学院 西安 710071

(zhou\_yt@stu.xidian.edu.cn)

**摘要** 随着信息技术与教育教学的深度融合,新型在线教育作为智慧教育的核心组成部分,为学习者提供了便捷的在线学习平台与丰富的学习资源。然而,在线教育模式的蓬勃发展也催生了“知识过载”与“知识迷航”等显著问题,极大地限制了学习者的学习增益与效率。近年来,学习资源推荐作为一种实现信息过滤与处理的关键技术手段,旨在分析学习者的历史学习行为,捕获其中蕴含的学习需求,最终实现千人千面的学习资源推荐服务。精准的个性化学习资源推荐能够有效解决在线教育场景中“知识过载”与“知识迷航”难题,实现个性化在线教育,已成为各大在线学习平台中不可或缺的核心功能之一。同时,随着深度学习技术的不断发展,基于深度学习的个性化学习资源推荐已成为计算机与教育交叉领域的研究焦点。因此,以“如何实现个性化学习资源推荐”和“如何实现对推荐结果的评估”两个问题为导向,对现有的研究工作进行了多维度、多层次、系统性的总结分析。首先,从场景特性、推荐目标、深度学习技术、边信息集成方式以及推荐模式 5 个维度对学习资源的个性化推荐过程进行分类与总结,以解答“如何实现个性化学习资源推荐”的问题;其次,从数据集、评估指标、以及实验方式 3 个方面对推荐结果的评估过程进行归纳与比较,并提供所有开源数据集的统一下载链接,以解答“如何实现对推荐结果的评估”的问题;最后,从对当前学习资源推荐方法自身局限性的攻克以及对外部新兴技术的利用与融合两个方面探讨了学习资源推荐未来的研究趋势。

**关键词:** 智慧教育;学习资源推荐;个性化;深度学习;知识图谱

**中图分类号** TP391

## Survey on Deep Learning-based Personalized Learning Resource Recommendation

ZHOU Yangtao, CHU Hua, ZHU Feifei, LI Xiangming, HAN Zihan and ZHANG Shuai

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

**Abstract** With the deep integration of information technology and education, novel online education, as a pivotal component of smart education, provides learners with convenient online e-learning platforms and rich learning resources. However, the rapid development of online education modes has also led to significant challenges such as “knowledge overload” and “knowledge disorientation”, which severely limits learners’ educational gains and efficiency. In recent years, learning resource recommendation, as a key technology for information filtering, aims to analyze learners’ historical behaviors, capture their underlying learning needs, and ultimately achieve personalized learning resource recommendation services. Accurate personalized learning resource recommendations can effectively address the challenges of “knowledge overload” and “knowledge disorientation” in online education, making it an indispensable core function in major online e-learning platforms. In addition, with the continuous advancement of deep learning technologies, research on deep learning-based personalized learning resource recommendation has become a focal area of interdisciplinary study in computer science and education. Therefore, this paper systematically analyzes existing research from multiple dimensions and levels, guided by the research questions of “how to achieve personalized learning resource recommendations” and “how to evaluate recommendation results”. Specifically, the paper firstly categorizes and summarizes the personalized recommendation process of learning resources from five dimensions, including characteristics, recommendation objectives, deep learning technologies, integration methods of side information, and recommendation patterns, to answer the question of how to realize personalized recommendation of learning resources. Second, this paper inductively compares the evaluation process of recommendation results from three aspects, including datasets, evaluation metrics, and experimental methods, and provides unified download links for all open-source datasets, to answer the question of how to evaluate the recommendation results. Finally, this paper explores future research trends of learning resource recommendation from two perspectives: overcoming the inherent

到稿日期:2024-04-15 返修日期:2024-07-08

基金项目:西安电子科技大学教育教学改革重点项目(A2304);中央高校基本科研业务费项目(ZYTS24092, QTZX24072, QTZX24085)

This work was supported by the Key Project of Education Teaching Reform of Xidian University(A2304) and Fundamental Research Funds for the Central Universities(ZYTS24092, QTZX24072, QTZX24085).

通讯作者:褚华(hchu@mail.xidian.edu.cn)

limitations of current recommendation methods as well as integrating and utilizing external emerging technologies.

**Keywords** Smart education, Learning resource recommendation, Personalization, Deep learning, Knowledge graph

## 1 引言

近年来,随着信息技术与教育教学的深度融合,我国乃至全世界的教育模式正面临着由传统线下教育模式到新型在线教育模式的急速转变<sup>[1]</sup>。新型在线教育作为智慧教育发展的核心组成,为学习者提供了便捷的在线学习平台与丰富的学习资源服务。这一模式突破了传统线下教育的时间与空间限制,使学习者能够根据个人的学习需求获取丰富且优质的学习资源,有效地缓解了传统教育模式下的数字鸿沟与教育公平问题<sup>[2]</sup>。据教育部统计<sup>1)</sup>,截至2023年12月,我国已建成30余个在线学习平台,如学堂在线、中国大学MOOC等,上线的慕课数量高达7.68万门,学习人数累计超过12.77亿人次。此外,慕课数量和应用规模仍呈现不断上涨的发展趋势。由此可见,在线学习平台已成为人们获取丰富知识的主要渠道。

然而,在线教育的高速发展在为学习者提供便利的同时,也催生了新的问题。一方面,学习资源的大量增加,引发了“知识过载(Knowledge Overload)”问题。这一问题致使学习者难以从海量的学习资源中快速且高效地筛选出满足自身需求的内容<sup>[3]</sup>。另一方面,“知识迷航(Knowledge Disorientation)”问题亦日渐显现。在缺乏实时的专家指导与课程规划的情况下,学习者面对良莠不齐的资源,容易迷失方向<sup>[4]</sup>。在这两大问题的影响下,学习者容易错误选择不适配自身需求与能力的学习资源,导致出现学习效率低下甚至学习失败等

不良现象。因此,在面对海量学习资源及多元化学习需求时,如何精准地感知学习者的个性化学习需求,并提供定制化的学习资源推荐服务,成为限制个人和在线教育发展的主要挑战。

为了应对上述挑战,智能推荐作为一种实现信息过滤与处理的关键技术手段,凭借其强大的个性化特征建模与表征能力,于近年来被广泛引入到在线教育领域中<sup>[3,5-6]</sup>。个性化学习资源推荐旨在深入分析学习者的历史学习行为,捕获其中蕴含的学习需求,以实现个性化的学习资源过滤,从而解决“知识过载”与“知识迷航”难题<sup>[7-9]</sup>。当前的学习资源推荐方法诉诸于深度学习网络,将历史学习行为数据中隐含的学习者的学习需求与学习资源的内容特征分别编码为向量表示,并通过两个向量之间的特征交互实现最终的学习资源过滤与推荐<sup>[5]</sup>。基于深度学习的个性化学习资源推荐已成为各大在线学习平台中不可或缺的核心功能之一。

目前,个性化学习资源推荐领域已取得一定进展,且随着MOOCs的发展,这一研究领域受到了广泛关注。已有综述分别从推荐目标<sup>[10]</sup>、建模方式<sup>[4]</sup>、推荐算法<sup>[11]</sup>等维度对现有的研究成果进行归纳总结。然而,这些综述研究仅基于单一维度对国内外相关的研究进行分类与总结,且缺乏对近几年大量涌现的新兴研究和技术的更新。区别于这些研究,本文以“如何实现个性化学习资源推荐”与“如何实现对推荐结果的评估”两个问题为导向,对现有的基于深度学习的学习资源推荐方法开展了综述研究,旨在为读者提供多维度、多层次、系统性的分析与总结。本综述整体的研究框架如图1所示。

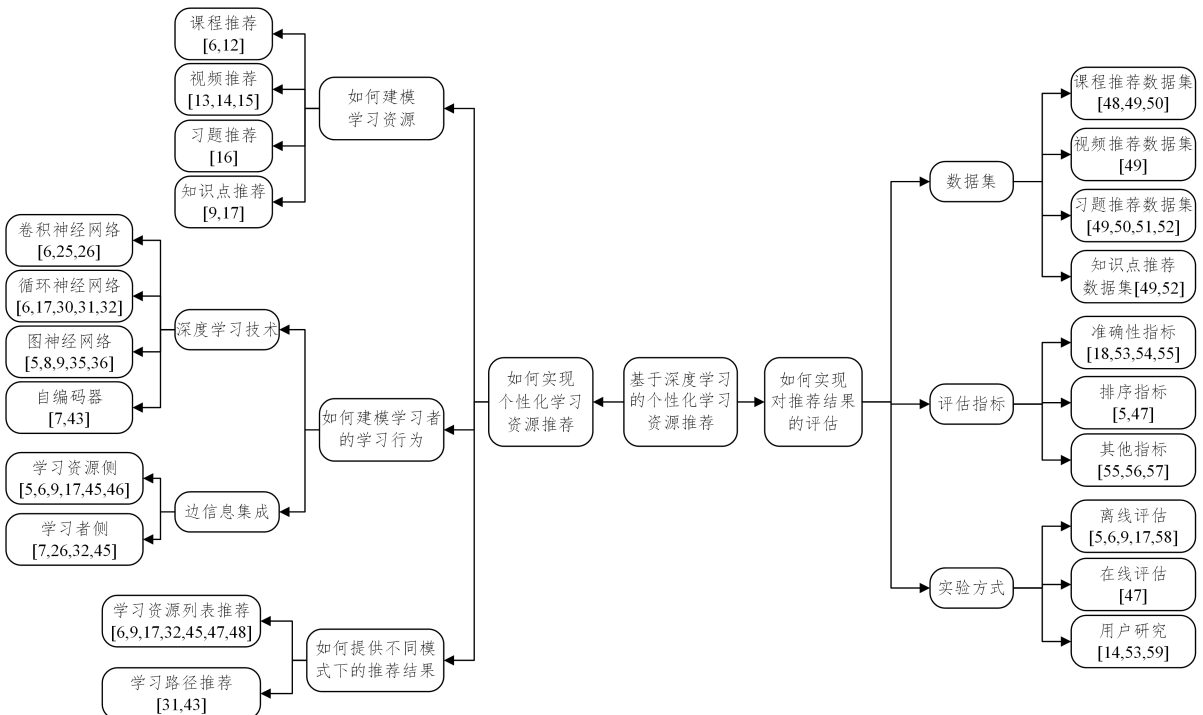


图1 基于深度学习的学习资源推荐方法的研究框架

Fig. 1 Research framework of learning resource recommendation methods based on deep learning

<sup>1)</sup> [http://www.moe.gov.cn/fbh/live/2024/55785/mtbd/202401/t20240126\\_1112589.html](http://www.moe.gov.cn/fbh/live/2024/55785/mtbd/202401/t20240126_1112589.html)

首先,针对“如何实现个性化学习资源推荐”问题,同时从场景特性、推荐目标、深度学习技术、边信息集成方式以及推荐模式 5 个维度对学习资源的个性化推荐过程进行全面且深入的总结与分析。其次,针对“如何实现对推荐结果的评估”问题,从数据集、评估指标以及实验方式 3 个方面对推荐结果的评估过程进行归纳与比较。最后,从对当前学习资源推荐方法自身局限性的攻克以及对外部新兴技术的利用与融合两个方面探讨了未来的研究趋势,为解决相关问题与挑战提供建议与指导。

本综述的具体贡献包括以下 4 个方面:

1)以问题为导向,对现有的个性化学习资源推荐方法进行系统性的研究与分析,具体包括“如何实现个性化学习资源推荐”及“如何实现对推荐结果的评估”两个问题。与现有的研究综述相比,本综述更具系统性,且讨论层次更深。

2)除了常见的技术分类外,从多种分类学角度对现有的研究工作进行综述,具体涵盖了场景特性、推荐目标、深度学习技术、边信息集成方式以及推荐模式 5 个方面。此外,本综述补充且更新了近期大量涌现的相关研究,以适应新技术的迭代发展。

3)为了保障研究实验的公平性与合理性,对现有研究工作所使用的数据集、评估指标以及实验方式进行横向对比与整理分析,并提供了所有公开数据集的统一下载链接,以便后续研究的推进。

4)对当前学习资源推荐方法自身存在的局限性进行总结分析,并从对当前局限性的攻克以及对外部新兴技术的利用与融合两个方面深入探讨了未来研究的发展趋势。

## 2 如何实现个性化学习资源推荐

不同于其他推荐场景,学习资源推荐场景具有 3 个显著特性。因此,本章首先将对学习资源推荐场景的特性进行深入分析;然后根据学习资源推荐场景的特性,“如何实现个性化学习资源推荐”问题可进一步拆解为“如何建模学习资源”“如何建模学习者的学习行为”“如何提供不同推荐模式下的推荐结果”3 个子问题;最后将分别围绕这 3 个子问题对当前的研究进展进行系统性综述,以详细分析当前研究对学习资源推荐场景 3 方面特性的建模考虑。

### 2.1 学习资源推荐场景的特性

相较于通用的推荐场景,学习资源推荐具有以下 3 方面的显著特性。

1)学习资源具有多样性。在线教育平台通常会为学习者提供多种类型的学习资源,如课程、视频、习题等。此外,有些平台还可能根据学习者的学习行为,评估其对知识点的掌握情况,为用户提供知识点推荐。学习资源的多样性要求推荐系统能够针对不同学习资源的类型特性分别进行推荐,故而有效且准确地建模不同类型的学习资源对提高个性化推荐的性能至关重要。

2)学习者的学习行为具有复杂性与稀疏性。与电商、新闻推荐这类仅受用户兴趣偏好驱动的场景不同,学习者的学习行为可能受到多种复杂因素共同驱动,如学习偏好/需求、知识之间的依赖关系等。这种复杂性无法被传统的启发式

推荐算法所捕获,如基于内容的推荐、基于协同过滤的推荐。与此同时,一门课程的学习通常需要花费学习者数周甚至数月的时间与精力,导致学习者与课程的交互数据显著稀疏于其他推荐场景。因此,如何充分利用先进的深度学习技术与领域知识来精准地刻画“学习者画像”并缓解数据稀疏性问题,是个性化学习资源推荐研究的核心任务。

3)学习资源推荐的模式具有多样性。系统为学习者提供推荐结果的模式通常包含 Top-K 学习资源列表和包含一系列有序学习资源的学习路径两大类。在 Top-K 学习资源列表推荐模式中,学习者通常具有较为明确的短期的学习目标,模型仅着眼于当下时刻用户的学习需求。而学习路径推荐一般需要自适应地提供一整套学习资源和活动序列,以形成适合用户的完整的学习路径,从而实现精准的学习过程引导。在这一模式中,学习者的学习时间相对更长,学习目标通常更加困难,推荐任务也更加复杂。

### 2.2 如何建模学习资源

由于学习资源具有多样性的场景特性,且每类学习资源各具特点,因此针对各学习资源的独有特点采取不同的策略进行建模至关重要,对推荐的性能和结果都具有十分重要的影响。从推荐目标的维度出发,当前的推荐方法可根据学习资源的类型划分为课程推荐、视频推荐、习题推荐以及知识点推荐四大类。

#### 2.2.1 课程推荐

课程推荐是当前在线教育平台最核心的功能,也是用户最常使用、需求最高的一项功能。在在线学习平台中,学习者与课程的交互为课程建模提供了重要的数据支撑,可以用来分析学习者的偏好和课程的内容特征。挖掘历史交互行为中学习者-课程或课程-课程间的潜在关系,是课程推荐建模的关键。

在建模学习者-课程交互关系时,现有的方法通常将学习者与课程的交互数据抽象为二部图,并将课程推荐任务转换为图上的链路预测任务。其中,学习者与课程被视作结点,而交互关系被视作连边。随后,图神经网络等致力于建模图式结构数据的深度学习技术被用来建模学习者与课程之间的高阶连通性,以捕获多跳的协同过滤信号,从而预测二部图上学习者与课程之间缺失的连边。例如,Xu 等<sup>[12]</sup>提出的基于超图的推荐方法 HGNN,将学习者表征的学习任务转化为超边的嵌入,通过改进的注意力机制学习课程的表示,随后利用图神经网络对课程信息进行传播和聚合,实现最终的推荐。

在建模学习者历史交互行为中的课程-课程关系时,现有的方法通常将每个学习者交互过的课程按照时间顺序排成序列,随后利用循环神经网络等序列化深度学习技术来建模这种序列化依赖关系,以捕获学习者对课程的动态偏好/需求。例如,Deng 等<sup>[6]</sup>提出了一种知识感知的序列化建模方法用于在线课程推荐,采用一个双向长短期记忆网络和一个卷积神经网络分别捕获课程之间点级和集体级的序列化依赖关系,以完善学习者的动态偏好特征提取。

#### 2.2.2 视频推荐

针对视频学习资源的推荐的核心是融合多模态数据的推荐,即提取与表征视频、字幕、图像等不同模态数据中所包含

的信息为低维向量,并进行对齐操作。具体而言,现有的视频学习资源推荐方法通常采用自然语言处理技术从视频的标题、字幕中提取信息完成建模。

Zhou 等<sup>[13]</sup>用 word2vec 为视频的标题生成嵌入,提取视频标题中所包含的知识点信息,并将其用作视频的内容特征。但它仅利用视频的标题信息,这要求视频的标题必须高度凝练且准确概括视频内容,对于标题拟定不清晰的视频无法完成推荐。Tang 等<sup>[14]</sup>应用快速自动关键词提取(Rapid Automatic Keyword Extraction, RAKE)算法,根据单词在视频字幕中出现的频率及其与其他单词的共现(co-occurrence)情况确定关键词,并引入维基百科词汇表和视频标签对收集到的关键词进行过滤以及关联关系分析。针对 word2vec 无法考虑上下文语义信息的问题,Wu 等<sup>[15]</sup>利用双向 Transformer 结构的 BERT 编码器获得课程的标题和字幕文本的词向量,接着采用多头注意力机制从不同语义空间捕获局部特征间的依赖关系,并输出最终文本特征的嵌入表示,实现对视频资源更准确的建模。

### 2.2.3 习题推荐

习题推荐的核心是基于学习者的答题情况、习题的难易程度、习题所包含的知识点等向学习者推荐有利于掌握或巩固尚未完全学会的知识。在绝大多数习题中,知识点是最直接反映学习者掌握目标知识程度的衡量标准,也能直接反映学习者在学习过程中存在的知识漏洞,因此知识点在准确建模习题特征方面具有重要贡献。对此,Jiang 等<sup>[16]</sup>提出了基于知识点层次图的个性化习题推荐算法,借鉴知识点体系结构的特点,构建了表征知识点层次关系的权重图,该权重图能够有效反映习题与知识点间的层次关系。

### 2.2.4 知识点推荐

知识点是所有学习资源中的最细粒度表示。每一个课程、视频、习题中都必然包含大量知识点,且每个知识点之间都存在着复杂的依赖关系,如包含、先修后继、互补等。如何利用知识点在结构上天然的层次或依赖关系对知识点结构进行合理建模,是知识点推荐的核心。Gong 等<sup>[9]</sup>通过异构信息网络和图卷积网络的方式将丰富的异构语义联系知识融入知识点实体的表达向量中,最后基于获得的学习者嵌入表达与知识点嵌入表达进行矩阵分解,从而实现知识点的推荐预测。在此基础上,Zhou 等<sup>[17]</sup>显式地集成了对知识点之间的先修后继的建模,并通过图神经网络与循环神经网络同时捕获学习者的静态与动态的学习需求,进一步提升了知识点推荐的性能。

## 2.3 如何建模学习者的学习行为

针对学习者学习行为具有复杂性与稀疏性的场景特性,如何准确地建模学习者的学习行为成为学习资源推荐系统设计的重要挑战之一。一方面,为了建模学习者学习行为的复杂性,深度学习技术可以通过大数据自动分析学习者的行为特征和历史交互来捕获隐藏在数据背后的潜在模式和复杂规律,于近年来被广泛引入到学习资源推荐的研究中<sup>[18-20]</sup>。另一方面,为了缓解学习行为的稀疏性影响,集成边信息的方法应运而生。除了学习行为数据,还可以考虑其他与学习者或学习资源相关的辅助信息,如学习者的学习目标、学习风格、

能力标签以及学习资源之间的关联关系等<sup>[21-22]</sup>。通过这些额外的边信息纳入建模过程中,可以更全面地理解学习者的学习行为,从而提高推荐系统的效果和可解释性。因此,本节将分别从基于深度学习技术的建模方式和集成边信息的建模方式两个方面进行研究分类与总结。

### 2.3.1 基于深度学习技术的建模方式

针对学习行为具有复杂性的场景特性,现有的学习资源推荐方法通过引入先进的深度学习技术来建模学习者复杂的交互行为数据,以提升推荐的性能。从深度学习技术的维度出发,现有的方法可根据所使用的深度学习技术的类型差异划分为 4 种类别:卷积神经网络、循环神经网络、图神经网络、自动编码器。

卷积神经网络(Convolutional Neural Network, CNN)<sup>[23]</sup>作为经典神经网络模型之一,在自然语言处理和图像处理等领域取得了显著的成果。CNN 的核心思想是通过卷积层和池化层等网络组件自动学习与提取序列数据(如文本序列等)的局部依赖特征<sup>[24]</sup>。在学习资源推荐任务中,CNN 通常被用于建模学习者/学习资源的文本描述信息或建模学习者的历史学习序列数据。例如,Shu 等<sup>[25]</sup>提出了一种基于 CNN 的基于内容的推荐算法,该算法使用 CNN 提取学习资源的文本信息作为学习资源的特征表示,同时结合由潜在因子模型从学习者的历史评分中学习到的学习者偏好特征,实现对课程推荐评分的预测。最近,Wang 等<sup>[26]</sup>将 CNN 应用于序列化交互数据的特征提取,提出了一种集成注意力机制的 CNN 来获取学习者配置并预测课程的推荐评分。该网络首先通过 CNN 编码学习者的序列化行为的特征,然后使用注意力机制计算预测评分与学习者提供的真实评分的差异性,并根据该差异性进行模型训练,最终利用训练好的模型提供个性化的课程推荐。此外,Deng 等<sup>[6]</sup>集成了课程知识图谱中的异构信息,并利用一个 CNN 来捕获学习者交互行为中的集体级序列化依赖,以增强学习者的动态偏好挖掘。虽然基于 CNN 的推荐方法取得了一定的成效,但 CNN 自身的网络结构设计限制了其对序列化数据的建模能力,导致其仅能捕获局部的序列化依赖,无法感知长序列中隐含的动态偏好特征。

近年来,循环神经网络(Recurrent Neural Network, RNN)已成为捕获时序数据中长期上下文信息的重要技术<sup>[27-28]</sup>。该网络已被广泛纳入学习资源推荐任务中,以建模交互序列数据中的长期序列化依赖关系。这些基于循环神经网络的方法通过深入挖掘完整的学习资源表征序列中的潜在状态变化,在学习者的动态偏好表征挖掘方面表现出色<sup>[29]</sup>。例如,Zhang 等<sup>[30]</sup>利用循环神经网络从一系列注册的课程序列中提取学习者的动态兴趣偏好,并利用基于内容的技术挖掘课程之间的关系,从而实现课程推荐。Zhou 等<sup>[31]</sup>根据特征相似性对学习者进行聚类操作,随后引入了循环神经网络的变体网络——长短期记忆网络(Long Short-Term Memory, LSTM),对学习者的学习行为中的序列化特征进行挖掘,以实现后续学习资源的预测和推荐。Ban 等<sup>[32]</sup>利用与时间相关的额外特征来增强 LSTM,用于对学习者的遗忘行为进行建模,并且还基于认知心理学理论,使用“个性”来建模学习者的个体差异,最终自适应地将学习者的知识水平与其序列化

行为结合起来,以生成学习者的表征。Zhou等<sup>[17]</sup>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,通过引入知识点之间的先修后继关系来增强对全局的静态学习需求的建模,并集成了循环神经网络的另一变体网络——门控循环单元网络(Gated Recurrent Unit, GRU),以建模学习者历史学习行为之间隐含的动态学习需求,从而显著地提高了学习资源推荐的性能。Deng等<sup>[6]</sup>提出了一种知识感知的序列化建模方法用于在线课程推荐,通过引入知识提供者来集成课程知识图谱中的异构信息,并采用一个双向LSTM和一个CNN分别捕获点级和集体级的序列化依赖,以精炼学习者的动态偏好特征。基于循环神经网络及其变体的推荐方法通过建模学习者的学习序列来剖析不同个体学习者的动态兴趣,是学习资源推荐研究中的主流分支之一。

图神经网络(Graph Neural Network, GNN)凭借其强大的图式结构建模与表征能力,于近年来被广泛引入并应用于学习资源推荐任务中<sup>[33]</sup>。通过将学习者与学习资源之间的交互关系抽象为二部图表示,图神经网络的邻居信息传播与聚合机制能够有效地建模学习者-学习资源二部图中的结点之间的高阶连通性,从而捕获到对推荐任务至关重要的协同过滤信号<sup>[34]</sup>。例如,Zhu等<sup>[35]</sup>提出了一种将图神经网络和张量分解融合的混合推荐模型,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丰富用户和课程的初始化特征表示,再通过随机游走以及贝叶斯概率张量分解实现推荐预测。Dai等<sup>[36]</sup>提出了一种基于图卷积神经网络的课程推荐系统,实现了“预处理-召回-离线排序-在线推荐-结果融合”的多端流水线原型,能够快速响应在线的课程推荐请求。Gong等<sup>[9]</sup>将学习者-知识点交互图与知识图谱合并为统一的异构信息网络,并在该异构信息网络应用多层图神经网络来捕获学习者对候选知识点的偏好。Zhang等<sup>[5]</sup>设计了一种知识分组网络,首先通过连接关系对异构信息网络进行分组,然后通过组内和组间两种注意力图卷积网络实现异构信息网络上的信息传播与聚合,从而强化学习者与学习资源的表征质量。不同于传统二部图结构的二元边设置,即一条边仅能连接两个结点,超图允许每条边连接多个结点,为探索更复杂的多元关系提供了独特的能力<sup>[37-38]</sup>。由于意识到超图在表征高阶多元关系方面的潜力,最近的前沿研究已经开始尝试引入超图神经网络(Hypergraph Neural Network, HGNN)以增强学习资源推荐的效果。例如,Wang等<sup>[8]</sup>引入超图神经网络建模学习者与课程之间的一对多关系,将学习者的表征学习任务转换为超边的嵌入学习任务,并设计了一种课程序列图编码器以捕获学习者长期与短期的学习需求,从而进一步提升了课程推荐的准确度。图神经网络对协同过滤信号的有效提取在以上工作中起到了关键支撑作用,高阶的信息传播与聚合机制让图神经网络能够探索任意多跳的连通性特征,在建模图式结构数据时表现非常优越。

自动编码器(Autoencoder, AE)凭借其高效特征编码与快速收敛的能力,在自然语言处理和计算机视觉领域获得了极大的关注<sup>[39-40]</sup>。这一成功激励了基于自动编码器的学习资源推荐方法的发展。这些方法旨在通过使用学习到的学习者和学习资源的特征表示来重建输入的学习者-学习资源

交互矩阵,从而预测缺失的交互<sup>[41-42]</sup>。自动编码器通常由编码器和解码器两部分组成。编码器将高维输入样本映射到低维抽象表示,从而实现特征提取与学习;解码器则将抽象表示转换为期望输出,实现对输入样本的重建。例如,Wang等<sup>[7]</sup>对学习者的先输入的技能属性特征进行主题建模,然后采用贝叶斯变分网络作为编码器完成对技能主题的特征抽取和迁移,以获得蕴含学习者学习需求的隐向量,最后与蕴含课程属性特征的课程隐向量一起输入矩阵分解解码器,实现培训课程的推荐预测。Chen等<sup>[43]</sup>使用自动编码器的思想实现了一个基于集合到序列排序的知识点感知的学习路径推荐模型。该模型在编码器中使用自注意力机制来捕获候选知识点之间的相关性,以学习候选知识点的全局表征。在解码器中,使用循环神经网络来对学习者的沿路径的知识状态进行建模,并通过注意力机制计算候选知识点与目标知识点之间的相关性,从而为每个候选知识点确定最合适的路径位置。基于自动编码器的推荐本质上是对学习者与学习资源交互数据的“编码”和“解码”过程,能够有效学习数据的分布并生成新的数据样本,从而提高推荐系统的效率和准确性。

### 2.3.2 集成边信息的建模方式

针对学习行为具有稀疏性的场景特性,现有的方法通过引入额外的边信息来补充和丰富学习者或学习资源的特征表示。从边信息集成方式的维度出发,这些方法可根据边信息的来源差异划分为两种类别:集成学习资源侧的边信息,如领域知识图谱等;集成学习者侧的边信息,如学习目标、学习风格、能力标签等。

1)集成学习资源侧的边信息。知识图谱是一种常见的学习资源侧的边信息。通过(头实体、关系、尾实体)三元组的形式,教育领域知识图谱中通常蕴含了学习资源之间丰富的关联关系,如课程-知识点的包含关系、知识点-知识点的先修后继关系等。集成知识图谱的学习资源推荐方法旨在应用多种不同的信息集成策略,如基于嵌入<sup>[44]</sup>、基于路径<sup>[9]</sup>以及基于传播<sup>[5]</sup>等,将领域知识图谱中的知识关联信息与学习者-学习资源的交互行为数据进行融合建模,在缓解数据稀疏性问题的同时提升推荐的性能,从而保障学习资源推荐的有效性。基于嵌入的方法主要利用图嵌入算法先对知识图谱进行编码,然后将得到的学习资源嵌入表征输入到推荐模型中进行推荐预测或排序,可灵活地与任意的下游推荐模型进行组合。例如,Deng等<sup>[6]</sup>应用TransD图嵌入技术学习知识图谱中的学习资源嵌入,然后将其用于初始化下游推荐任务中的学习资源表征。此外,Yang等<sup>[45]</sup>提出一种注意力关系感知的图嵌入方法来实现对知识图谱的学习资源及关系嵌入,随后通过深度神经网络技术实现学习者表征与课程表征的特征交互,从而实现领域知识增强的课程推荐。基于路径的方法主要通过元路径/元图的方式将知识图谱中实体和关系的语义路径注入到学习者-学习资源的交互行为输入中,实现端到端的模型训练。例如,Gong等<sup>[9]</sup>提出了一种基于端到端的异构视图注意力图卷积网络,将领域知识图谱与学习者-学习资源交互图合并为统一的异构信息网络,然后通过元路径引导异构信息网络上的信息传播与聚合,从而捕获学习者对候选知识点的学习需求分布。进一步地,Zhou等<sup>[17]</sup>显式地引入知识点

之间先修后继关系的元路径来建模全局的静态学习需求,显著地提升了知识点推荐的性能。基于传播的方法则是在由知识图谱与学习者交互行为数据统一合并后的异构信息网络上,通过图神经网络执行全局的信息传播与聚合,以直接学习到学习者与学习资源的表征。例如,Alatrash 等<sup>[46]</sup>使用预训练语言模型编码器 SBERT 生成知识图谱中各个实体的初始向量表示,随后使用图卷积神经网络来传播和聚合邻居实体的向量表示,从而在实体中融合丰富的语义信息,得到更加精准的推荐结果。Zhang 等<sup>[5]</sup>则设计了一种知识分组网络,首先通过链接关系对异构信息网络进行分组,然后通过组内和组间两种注意力图卷积网络实现异构信息网络上的信息传播与聚合,从而强化学习者与学习资源的表征质量。综上所述,当前的集成学习资源侧的边信息的方法均致力于探索如何更有效地融合额外的领域知识图谱信息,以进一步增强学习资源的表征质量,从而缓解交互行为高度稀疏的影响,使推荐结果更加准确。

2)集成学习者侧的边信息。学习者侧的边信息包括学习者事先输入在线学习平台中的人口统计学信息、学习目标、学习风格、能力标签等。引入学习者侧的边信息可以补充强化学习者的特征表示,从而缓解数据稀疏性问题的影响并提高学习者的满意度。例如,Wang 等<sup>[26]</sup>将学习者的人口统计信息和在线行为统计信息融入到推荐模型中,以增强学习者偏好的提取。除了利用学习者的人口统计信息外,与学习者能力等级相关的信息也有助于对学习者的提取。例如,Wang 等<sup>[7]</sup>从学习者的技能档案中提取学习者能力的潜在可解释表示,通过这些辅助技能信息来加深模型对学习者的了解,也可以缓解数据稀疏和冷启动问题。除了直接将学习者侧的边信息融入学习者表征外,Yang 等<sup>[45]</sup>利用学习者的配置信息(比如年龄、行业、位置等)来计算学习者之间的相似度,并结合相似学习者来得到新学习者的特征表示。对于已有历史交互的学习者,则是通过历史交互来建模学习者偏好。除了学习者的显式信息之外,学习者的隐式信息也能够为建模学习者个性化偏好提供帮助。例如,Ban 等<sup>[32]</sup>受认知心理学理论的启发,将学习者的个性/性格整合到学习者的特征表示学习过程中,以进一步考虑个体的差异。虽然学习者侧的边信息有助于缓解数据稀疏性问题的影响,但这些信息因为涉及学习者隐私问题,通常在实际应用场景中难以获取,限制了集成学习者侧的边信息的研究发展。

#### 2.4 如何提供不同模式下的推荐结果

针对推荐模式具有多样性的特性,从推荐模式的维度出发,系统为学习者推荐的内容通常可根据推荐模式的差异划分为学习资源列表和包含一系列学习资源的学习路径两大类。

1)学习资源列表推荐:旨在聚焦于从行为数据中挖掘得到学习者的个性化特征,并根据个性化特征自动为学习者提供他们可能感兴趣或需要的 Top-K 个学习资源组成的列表。其中,K 是一个可人为配置的超参数,且推荐列表中的学习资源之间没有明确的先后顺序。例如,Gong 等<sup>[9]</sup>和 Zhou 等<sup>[17]</sup>首先通过深度神经网络编码获得学习者与学习资源的特征表示;然后直接利用矩阵分解技术计算学习者与未观察到的学习资源之间的交互概率,并按照交互概率的大小进行降序

排序;最后根据排序结果生成学习者在下一时刻可能交互的 Top-K 课程推荐列表。当前,基于深度学习的学习资源推荐研究主要是面向学习资源列表模式的推荐<sup>[6,32,45,47-48]</sup>。

2)学习路径推荐:偏向于综合考虑目标学习者的学习能力、知识背景、学习目标等的差异性,从候选的学习资源中为学习者推荐一系列连续且具有明确先后顺序的学习资源<sup>[3]</sup>。相较于学习资源列表推荐,个性化学习路径推荐方法不仅需要考虑到学习者的偏好,更为重要的是需要满足教育学规律,如连续的学习资源的学习难度应该尽可能地平滑过渡,学习资源的前后顺序应该满足先修关系约束等,还应融合知识追踪技术,对学习者的当前知识掌握能力做出准确判断,以提供最符合学习者所处学习阶段的推荐结果。例如,Chen 等<sup>[43]</sup>将学习路径推荐任务建模为一个“集合到序列”的问题,通过引入处理学习者正在学习的知识点和目标知识点之间相关性的注意力机制,逐步生成学习路径。Zhou 等<sup>[31]</sup>利用聚类技术和 LSTM 网络,根据学习者的学习过程或访问过的材料,预测学习者在可能的学习路径上的学习表现,从而实现学习路径推荐。

### 3 如何实现对推荐结果的评估

在个性化学习资源推荐的评估阶段,规范的数据集、统一的评估指标以及全面的实验方式有助于确保评估的客观性、公平性与系统性,从而保障推荐结果的有效性。因此,本章主要对现有的个性化学习资源推荐方法常用的公开数据集、评估指标与实验方式进行整理与分析。特别地,本章汇总并提供了收集到的公开数据集的官方下载链接,供后续研究人员使用。

#### 3.1 数据集

根据学习资源的类型差异,当前的公开数据集可划分为课程推荐数据集、视频推荐数据集、习题推荐数据集以及知识点推荐数据集 4 类。图 2 展示了各类数据集中主要公开数据集的数量。其中,课程推荐数据集主要是从各大 MOOC 平台收集得到的学习者选课记录;习题推荐数据集主要是从各大在线实践教学平台收集的学习者解题记录;目前专门用于视频推荐和知识点推荐的数据集相对较少,许多视频推荐和知识点推荐的相关研究往往依赖于课程推荐数据集或习题推荐数据集进行评估。




图 2 各类公开数据集数量统计

Fig. 2 Statistics of the numbers of various public datasets

本节总结了目前主要的个性化学习资源推荐公开数据集,并对公开数据集的数据信息进行统计分析,如表 1 所列。

表 1 常用数据集统计信息

Table 1 Statistics of common datasets

数据集	学习者总数	课程总数	视频总数	习题总数	知识点总数	交互记录数
MOOCCube	199199	706	38181	—	114563	5557051
MOOCCourse	82535	1302	—	—	—	458454
edX	4500000	290	—	—	—	884883
Canvas Network	224914	238	—	—	—	325199
ASSITments09	4163	—	—	17751	120	337990
OULAD	32593	7	—	—	—	16655280
KDDCup Algebra	574	—	—	1085	437	809694
OLI Engineering Statics 2011	335	—	—	300	87	45002
MOOPer	46743	600	—	1360	—	25000000
Junyi	72630	—	—	835	712	16217311
EdNet	784309	1021	—	13169	—	131441538
POJ	22916	—	—	2751	—	996240
BePKT	906	—	—	1054	106	317418

## 1) MOOCCube 数据集

MOOCCube 数据集<sup>1)</sup>是由 Yu 等<sup>[49]</sup>于 2020 年从中国最大的 MOOC 平台之一——学堂在线,收集得到的开放数据集。该数据集提供了 706 门真实在线课程、38181 个教学视频、114563 个知识点、199199 名 MOOC 学习者的数十万选课和视频观看记录。此外,MOOCCube 还包含一个知识图谱,该图谱不仅明确了各知识点之间的先修后继关系,还细致描绘了它们之间的层次关系,如某一广泛知识点包含了哪些具体的知识点。MOOCCube 数据集可用于支撑课程推荐、视频推荐、习题推荐和知识点推荐的研究。

## 2) MOOCCourse 数据集

MOOCCourse 数据集<sup>2)</sup>是由 Zhang 等<sup>[48]</sup>收集于学堂在线的公开数据集。该数据集只保留在 2016 年 10 月 1 日到 2018 年 3 月 31 日期间学习课程不少于 3 节的学习者交互记录,并将不同年份的课程视为同一课程。处理后的数据集提供了 23 个类别的 1302 门课程,以及 82535 个学习者产生的 458454 个学习者-课程的学习记录交互对。此外,该数据集提供了学习者观看的每个课程视频的持续时间。MOOC-Course 数据集可用于支撑课程推荐的研究。

## 3) edX 数据集

edX 数据集<sup>3)</sup>是由 edX 平台收集并发布的公开数据集。其中,edX 平台是麻省理工学院和哈佛大学共同创立的非营利性学习平台。该数据集提供了自 2012 年以来 edX 平台上的 290 门哈佛和麻省理工学院在线课程,涵盖 25 万次认证、450 万参与者和 2800 万参与小时的数据。edX 数据集可用于支撑课程推荐的研究。

## 4) Canvas Network 数据集

Canvas Network 数据集<sup>4)</sup>是由 Canvas Network 发布的公开数据集。Canvas Network 是美国的一个开放在线课程

平台。该数据集包含了来自 Canvas Network 平台的 238 门课程,涵盖了 10 个学科门类。该数据集提供了 2014 年 1 月至 2015 年 9 月期间 224914 名学习者的 325199 条学习行为记录。Canvas Network 数据集可用于支撑课程推荐的研究。

## 5) ASSISTments 数据集

ASSISTments 数据集<sup>5)</sup>是 Dr. Heffernan 从 ASSISTments 在线学习平台收集的一系列数据集。其中最广泛使用的数据集来自 2009 至 2010 学年。ASSISTments 数据集可用于支撑课程推荐和知识点推荐的研究。

## 6) 英国开放大学学习分析数据集(OULAD)

OULAD(Open University Learning Analytics Dataset)<sup>6)</sup>是英国开放大学发布的公开学习分析数据集。该数据集提供了 2013 至 2014 年期间英国开放大学的 7 门在线课程的 32593 条学习者注册信息、173912 行任务得分记录以及 16655280 行交互记录。OULAD 数据集可用于支撑课程推荐的研究。

## 7) KDDCup Algebra 数据集

KDDCup Algebra 数据集<sup>7)</sup>是由 2010 年 KDDCup 教育数据挖掘挑战赛发布的公开数据集。KDDCup 是一个年度数据挖掘和知识发现竞赛。2010 年,KDDCup 教育数据挖掘挑战赛提供了收集于不同年份的代数练习序列数据集,包含从 2005 至 2006 年期间 574 名学习者的 809694 条解题记录,涉及 437 个知识点和 1085 个习题。KDDCup Algebra 数据集可用于支撑习题推荐和知识点推荐的研究。

## 8) OLI Engineering Statics 2011 数据集

OLI Engineering Statics 2011 数据集<sup>8)</sup>记录了 2011 年一门大学水平的工程静力学课程的学生练习记录。该数据集包含 335 名学习者、300 个习题以及 87 个知识点,共提供了 45002 条学习者-习题的交互记录。OLI Engineering Statics 2011 数据集可用于支撑习题推荐和知识点推荐的研究。

<sup>1)</sup> <http://moocdata.cn/data/MOOCCube>

<sup>2)</sup> <http://moocdata.cn/data/course-recommendation>

<sup>3)</sup> <https://www.kaggle.com/datasets/edx/course-study>

<sup>4)</sup> <https://dataverse.harvard.edu/dataverse/cn>

<sup>5)</sup> <https://www.etrilstestbed.org/resources/featured-studies/dataset-papers>

<sup>6)</sup> [https://analyse.kmi.open.ac.uk/open\\_dataset](https://analyse.kmi.open.ac.uk/open_dataset)

<sup>7)</sup> <https://pslclatashop.web.cmu.edu/KDDCup/downloads.jsp>

<sup>8)</sup> <https://pslclatashop.web.cmu.edu/Project?id=48>

### 9) MOOPer 数据集

MOOPer 数据集<sup>1)</sup>是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<sup>[50]</sup>。其中,MOOP 指大规模在线开放实践(Massive Open Online Practice)。该数据集提供了 2018 至 2019 年期间 EduCoder 平台的 2 532 524 条练习数据、21 606 390 条系统反馈数据以及 15 054 条用户论坛讨论数据。该数据集还提供了一个知识图谱,其中包含 11 类实体和 10 类关系。MOOPer 数据集可用于支撑课程推荐和习题推荐的研究。

### 10) Junyi 数据集

Junyi 数据集<sup>2)</sup>是 Junyi Academy 发布的公开数据集。其中,Junyi Academy 是一个成立于 2012 年的在线学习平台,提供覆盖从小学到高中的相关视频与习题。该数据集提供了 2018 年 8 月至 2019 年 7 月期间 72 630 位学生在 Junyi Academy 平台上的 16 217 311 次解题记录,可用于支撑习题推荐和知识点推荐的研究。

### 11) EdNet 数据集

EdNet 数据集<sup>3)</sup>是由韩国的多平台人工智能辅导服务 Santa 发布的公开数据集。该数据集提供了 2017 年至 2019 年间 784 309 名学生在 Santa 人工智能辅导平台的互动记录,总计 131 441 538 次。平均而言,每位学生与系统的交互次数为 441.20 次。该数据集是目前最大的公开教育数据集之一,可用于支撑课程推荐和习题推荐的研究。

### 12) POJ 数据集

POJ(Peking Online Judge)数据集<sup>4)</sup>是 Pandey 等<sup>[51]</sup>从北京大学在线代码实践平台收集的公开数据集。该数据集提供了 22 916 位学生与 2751 个练习的 996 240 次交互,平均每位学生有 43.47 个练习记录。POJ 数据集可用于支撑习题推荐的研究。

### 13) BePKT 数据集

BePTK 数据集<sup>5)</sup>是由 Zhu 等<sup>[52]</sup>从其所在大学的在线评测系统中收集得到的公开数据集。该数据集提供了 2019 年 9 月至 2021 年 7 月期间 906 名用户对在线评测系统中编程问题的 240 759 条点击记录与 76 657 条提交记录。该数据集包含 1 054 个习题、106 个知识点以及 1 054 个带注释的习题-知识点对。BePTK 数据集可用于支撑习题推荐和知识点推荐的研究。

## 3.2 评估指标

为了客观且公平地评估个性化学习资源推荐方法的效果,本节整理并介绍了个性化学习资源推荐实验中常用的评估指标,并将其划分为 3 种类型:准确性指标、排序指标以及其他指标。各类常用评估指标的数据统计信息如图 3 所示。




图 3 各类评估指标数量统计

Fig. 3 Statistics of the number of various evaluation metrics

### 3.2.1 准确性指标

命中率(Hit Ratio, HR):当学习者的推荐列表中至少包含一个学习者真正交互过的学习资源时,称该学习者的推荐结果命中<sup>[18]</sup>。命中率是指推荐结果中被命中的学习者数量与总学习者数量的比率。命中率 HR 的计算公式如下:

$$HR = \frac{\sum_{u \in U} I(T_u \cap R_u \neq \emptyset)}{|U|} \quad (1)$$

其中, $U$ 表示学习者集合, $|U|$ 表示学习者的总数; $T_u$ 表示测试集中学习者 $u$ 实际交互过的学习资源集合, $R_u$ 表示模型推荐给学习者 $u$ 的学习资源集合; $I(\cdot)$ 为一个标识函数,在测试条件为真时取值为 1,否则为 0。

精确率(Precision):衡量学习者真正感兴趣的学习资源与推荐的学习资源之间的匹配程度,定义为推荐结果中学习者实际交互过的学习资源数量与推荐列表中所有学习资源数量的比值<sup>[53]</sup>。对于学习者 $u$ ,其精确率  $Precision_u$  的计算公式为:

$$Precision_u = \frac{N_{ip}}{|R_u|} \quad (2)$$

其中, $N_{ip}$ 表示推荐结果中学习者实际交互过的学习资源的数量, $R_u$ 表示模型推荐给学习者 $u$ 的学习资源集合, $|R_u|$ 表示推荐列表中学习资源的总数。最后,将所有学习者的精确率进行求和并计算平均值,得出整个模型的 Precision 指标评估结果。

召回率(Recall):衡量推荐系统成功捕捉到学习者真正感兴趣的学习资源的能力,定义为推荐结果中学习者实际交互过的学习资源数量与学习者实际交互的所有学习资源数量的比值<sup>[53]</sup>。对于学习者 $u$ ,其召回率  $Recall_u$  的计算公式为:

$$Recall_u = \frac{N_{ip}}{|T_u|} \quad (3)$$

其中, $N_{ip}$ 表示推荐结果中用户实际交互过的学习资源的数量, $T_u$ 表示测试集中用户 $u$ 真实交互的学习资源集合, $|T_u|$ 表示测试集中用户 $u$ 真实交互的学习资源数量。最后,将所有用户的召回率进行求和并计算平均值,得出整个模型的 Recall 指标评估。

<sup>1)</sup> <https://www.educoder.net/ch/rest/4>

<sup>2)</sup> <https://www.kaggle.com/datasets/junyiacademy/learning-activity-public-dataset-by-junyi-academy>

<sup>3)</sup> <https://github.com/rriid/ednet>

<sup>4)</sup> [https://drive.google.com/drive/folders/1LRljqWfODwTYRMPw6wEJ\\_mMt1KZ4xBDk](https://drive.google.com/drive/folders/1LRljqWfODwTYRMPw6wEJ_mMt1KZ4xBDk)

<sup>5)</sup> <https://drive.google.com/drive/folders/1Jt6f0MV1paGLlctJqxHtdF1Vh2mUnsoV>

F1 值: Precision 和 Recall 的调和平均值<sup>[53]</sup>。F1 值的计算式为:

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

其中, Precision 表示所有用户的平均准确率, Recall 表示所有用户的平均召回率。

准确率(Accuracy): 衡量推荐系统在整个数据集上正确推荐的样本所占的比例, 定义为推荐系统正确推荐的样本数与总样本数的比值<sup>[53]</sup>。准确率 Accuracy 的计算式为:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

其中, TP(True Positives)表示推荐模型正确地将正样本预测为正样本的数量; FP(False Positives)表示推荐模型错误地将负样本预测为正样本的数量; FN(False Negatives)表示推荐模型错误地将正样本预测为负样本的数量; TN(True Negatives)表示推荐模型正确地将负样本预测为负样本的数量。

平均绝对误差(Mean Absolute Error, MAE): 衡量推荐预测的准确性, 定义为预测值与实际观测值之间的绝对差值的平均值<sup>[35]</sup>。对于学习者  $u$ , 其平均绝对误差  $MAE_u$  的计算式为:

$$MAE_u = \frac{1}{|R_u|} \sum_{i \in R_u} |y_i - \hat{y}_i| \quad (6)$$

其中,  $R_u$  表示模型推荐给学习者  $u$  的学习资源集合,  $|R_u|$  表示推荐结果中学习资源的数量,  $\hat{y}_i$  表示推荐模型对学习资源  $i$  的预测评分,  $y_i$  表示学习者对学习资源  $i$  的真实评分。最后对所有学习者的均方根误差进行求和平均, 以获得整个模型的 MAE 指标评估。

均方根误差(Root Mean Square Error, RMSE): 衡量预测的准确性, 定义为预测值与实际观测值之间的平方差的均方根<sup>[35]</sup>。对于学习者  $u$ , 其均方根误差  $RMSE_u$  的计算式为:

$$RMSE_u = \sqrt{\frac{\sum_{i \in R_u} (\hat{y}_i - y_i)^2}{|R_u|}} \quad (7)$$

其中,  $R_u$  表示模型推荐给学习者  $u$  的学习资源集合,  $|R_u|$  表示推荐结果中学习资源的数量,  $\hat{y}_i$  表示模型对学习资源  $i$  的预测评分,  $y_i$  表示学习者对学习资源  $i$  的真实评分。最后对所有学习者的均方根误差进行求和平均, 以获得整个模型的 RMSE 指标评估。

### 3.2.2 排序指标

归一化折损累计增益(Normalized Discounted Cumulative Gain, NDCG): 一种衡量推荐系统排序质量的指标, 它考虑了推荐列表中学习资源的顺序<sup>[5]</sup>。其计算步骤如下: 对于学习者  $u$ , 推荐列表中有  $p$  个学习资源, 首先计算推荐学习资源列表的折损累计增益  $DCG_p$ :

$$DCG_p = \sum_{i=1}^p \frac{rel_i}{\log_2(i+1)} \quad (8)$$

其中, 如果预测的学习资源所在顺序位置与测试集中真实的顺序位置相同, 则相关度  $rel_i$  赋值为 1, 否则赋值为 0。然后, 定义理想情况下的折损累计增益  $IDCG_p$  来表示测试集中学习者真实交互的前  $N$  个学习资源的理想排序。在理想排序中, 每个学习资源的位置完全匹配学习者的实际交互顺序。

$IDCG_p$  的计算式如下:

$$IDCG_p = \sum_{i=1}^{REL_p} \frac{rel_i}{\log_2(i+1)} \quad (9)$$

其中,  $REL_p$  表示测试集中学习者真实交互的前  $p$  个学习资源。在确定了推荐列表的  $NDCG_p$  以及相应的  $IDCG_p$  之后,  $NDCG_p$  定义为  $DCG_p$  与  $IDCG_p$  之比, 旨在对折损累计增益进行归一化处理。 $NDCG_p$  的计算式如下:

$$NDCG_p = \frac{DCG_p}{IDCG_p} \quad (10)$$

平均倒数排名(MRR): 衡量系统在给定学习者的情况下, 将最相关的推荐项目排在最前面的能力<sup>[47]</sup>。针对每个学习者, 在推荐列表中找到其相关的第一个学习资源的排名, 计算其排名的倒数, 然后将所有学习者的倒数排名取平均, 即可得到 MRR 值。其计算式如下:

$$MRR = \frac{1}{N} \sum_{i=1}^N \frac{1}{p_i} \quad (11)$$

其中,  $N$  表示学习者总数,  $p_i$  表示第  $i$  个学习者真实交互的学习资源在推荐列表中的位置。

AUC 值: 衡量推荐系统在对正负样本进行排序时, 将正样本排在负样本前面的概率, 定义为 ROC(Receiver Operator Curve)曲线下的面积<sup>[54]</sup>。ROC 曲线是一种绘制正例真阳率 TPR(True Positive Rate)和负例假阳率 FPR(False Positive Rate)之间关系的曲线。其中, TPR 是指在实际为正例的样本中, 被正确预测为正例的比例; FPR 是指在实际为负例的样本中, 被错误分类为正例的比例。TPR 和 FPR 的计算公式如下:

$$\begin{cases} TPR = \frac{TP}{TP + FN} \\ FPR = \frac{FP}{FP + TN} \end{cases} \quad (12)$$

### 3.2.3 其他指标

多样性(Diversity): 衡量推荐学习资源的差异性。多样性可以用推荐列表中所有学习资源的平均差异度来表示。Wu 等<sup>[55]</sup>使用学习资源间的余弦相似度来衡量学习资源之间的相似程度, 则两个不同学习资源的差异度可表示为:

$$diff(e(K)_i, e(K)_j) = 1 - \frac{e(K)_i \cdot e(K)_j}{\|e(K)_i\| \|e(K)_j\|} \quad (13)$$

其中,  $e(K)_i$  和  $e(K)_j$  表示推荐列表中的不同学习资源。列表中不同学习资源的差异度越大, 说明推荐学习资源的多样性越高。整个推荐列表的多样性  $Div$  可表示为:

$$Div(L_R) = \frac{2 \sum_{q(K)_i, q(K)_j \in L_R, i \neq j} diff(q(K)_i, q(K)_j)}{|R|(|R|-1)} \quad (14)$$

其中,  $|R|$  表示推荐学习资源的总数,  $L_R$  表示有  $e(K)$  个学习资源的推荐列表,  $q(K)_i$  和  $q(K)_j$  表示推荐列表中两个不同的学习资源。

新颖性(Novelty): 衡量推荐的新颖程度。新颖的学习资源是指那些包含目标学习者未曾接触或未能正确掌握的知识点的学习资源<sup>[55]</sup>。学习资源  $e(K)$  涵盖的一组知识点定义为  $\Omega(e(K))$ , 可表示为:

$$\Omega(e(K)) = \{k_i | e(k_i) = 1\} \quad (15)$$

其中,  $e(k_i) = 1$  表示学习资源  $e(K)$  涵盖了第  $i$  个知识点,

则被成功掌握的学习资源所涵盖的知识点集合可以表示为:

$$\Omega(e(K)^m) = \bigcup_{e(k_i)^m \in H} \{k_i | e(k_i)^m = 1\} \quad (16)$$

其中,  $e(K)^m$  表示被成功掌握的学习资源。在评估新颖性时, 将两个学习资源的距离表示为:

$$\text{dist}(e(K), e(K)^m) = 1 - \text{Jacc}(\Omega(e(K)), \Omega(e(K)^m)) \quad (17)$$

其中,  $\text{Jacc}(\Omega(e(K)), \Omega(e(K)^m))$  表示  $\Omega(e(K))$  和  $\Omega(e(K)^m)$  之间的 Jaccard 相似度。系统所推荐学习资源与被成功掌握的学习资源的距离越大, 则推荐结果的新颖性就越高。因此, 推荐结果的新颖性可表示为:

$$\text{Novelty}(L_R) = \frac{1}{|R|} \sum_{r=1}^R \text{dist}(e(K), r) \quad (18)$$

其中,  $R$  表示推荐习题列表,  $|R|$  表示推荐习题总数,  $L_R$  表示有  $|R|$  个推荐习题的推荐列表。

**正确作答率:** 在个性化习题推荐场景中, Zhu 等<sup>[56]</sup> 提出了评估推荐习题难度合理性的指标, 用来衡量推荐试题难度是否符合学习者实际水平。正确作答率定义为在设定推荐习题的难度范围后, 学习者正确作答的习题数与推荐习题的总数的比值。正确作答率的计算公式为:

$$\text{SR} = \frac{\text{right}}{\text{total}} \quad (19)$$

其中,  $\text{total}$  为推荐试题的总数,  $\text{right}$  为学生正确作答的试题数。

**推荐难度准确性:** 为了衡量推荐的习题难度是否符合预期, Wu 等<sup>[55]</sup> 计算了推荐列表中每个习题的难度与目标难度  $\delta$  之间的相对距离。对于推荐练习  $i$ , 其与目标难度的相对距离为  $|\delta - D_{e(K)_i}|$ ,  $D_{e(K)_i}$  是推荐习题  $i$  的难度。由于此相对距离的取值范围是  $0 \sim 1$ , 且该值越小, 习题的难度越接近所期望的难度, 因此可以使用  $1 - |\delta - D_{e(K)_i}|$  代表推荐习题  $i$  的难度准确性。那么, 整个推荐列表的难度准确性可表示为:

$$\text{Accuracy}(L_R) = \frac{\sum_i (D_{q(K)_i})}{|R|} \quad (20)$$

其中,  $D_{q(K)_i} = 1 - |\delta - D_{e(K)_i}|$ ,  $R$  表示推荐习题列表,  $|R|$  表示推荐习题总数,  $L_R$  表示有  $|R|$  个推荐习题的推荐列表。

**学习效果 (Learning Effect):** 衡量学习路径的常用指标<sup>[57]</sup>。学习路径  $p$  的学习效果  $E_p$  可表示为:

$$E_p = \frac{E_{\text{end}} - E_{\text{start}}}{E_{\text{sup}} - E_{\text{start}}} \quad (21)$$

其中,  $E_{\text{start}}$  代表学习者在学习路径  $p$  之前对目标知识点的掌握程度;  $E_{\text{end}}$  代表学习者在学习路径  $p$  之后对目标知识点的掌握程度;  $E_{\text{sup}}$  代表掌握程度的上限, 掌握程度可以从考试中获得。

### 3.3 实验方式

目前评估个性化学习资源推荐的实验方式主要包括离线评估、在线评估和用户研究 3 种。本节将对个性化学习资源推荐的 3 种主要实验方式进行详细介绍。

#### 3.3.1 离线评估

离线评估是指在离线数据集上对推荐模型进行训练与优化, 并使用特定评估指标来量化推荐模型性能的评估方法。例如, Lin 等<sup>[58]</sup> 为了验证其提出框架的有效性, 在两个真实

世界数据集 MOOCube 和 MOOCourse 上进行了离线评估。Zhang 等<sup>[5]</sup> 在 MOOCube 和 BOOKCrossing 两个真实世界数据集上, 针对 CTR 预测和 Top-K 推荐两种场景进行了离线评估, 以全面评估其提出的 KGAN 框架的性能。

离线评估作为评估个性化学习资源推荐效果的主要实验方式, 其数据获取方便, 可利用公开数据集或现有数据进行模型评估, 从而节省了数据收集的成本和时间。其次, 离线评估的实验数据安全性高, 尤其是在使用公开数据集时, 数据经过脱敏处理, 有效保护了用户隐私。此外, 离线评估还具有可重复性高、易于验证结果的稳定性和一致性等优点。然而, 离线评估也存在一些缺点。首先, 由于所使用的数据集可能与实际场景的数据分布存在差异, 因此离线评估的可靠性不足, 导致评估结果的准确性有待验证。此外, 离线评估缺乏实时性, 无法反映学习者行为的实时变化。

#### 3.3.2 在线评估

在线评估是指在实际生产环境中应用推荐模型并对真实用户行为数据进行计算和评估的实验方式。在线评估通常结合 A/B 测试进行, 即将用户分成 A 组和 B 组, 并在不同用户组中应用不同的推荐模型, 以比较不同模型在真实推荐场景中的推荐效果。此外, 在线评估通常与离线评估相结合, 以综合评估模型的性能。Jing 等<sup>[47]</sup> 将其提出的框架部署到了学堂在线, 并收集了该框架在部署后第一个月的日志作为在线数据集。然后, 该研究将在线数据集和离线数据集结合使用, 对模型进行了综合评估。

在线评估作为评估个性化学习资源推荐系统的另一种重要实验方式, 具有诸多优点和缺点。其优点包括实时性强, 能够及时反映用户行为和模型效果的变化, 有助于及时调整推荐策略以提升用户体验; 可信度高, 通过利用真实用户数据进行评估, 更贴近实际应用场景, 评估结果更可信。然而, 在线评估的成本较高, 需要投入大量人力和资源, 且可能存在推荐错误导致的用户流失和收益损失等风险。此外, 在线评估需要足够的用户量来获取可靠的实验结果, 而新推出的产品或服务难以吸引足够的用户量来提供可靠的实验结果。

#### 3.3.3 用户研究

用户研究是通过让用户体验推荐系统并收集用户对推荐结果的反馈, 来评估模型性能的实验方法。用户反馈的形式包括对推荐结果打分、填写用户调查问卷, 以及参与用户采访等。Tang 等<sup>[14]</sup> 在评估其提出的系统 ConceptGuide 时, 招募了 16 位参与者, 每位参与者分别使用 YouTube 和 ConceptGuide 完成两项学习任务, 最后通过问卷调查和访谈的方式对两种学习体验进行比较。Zhang 等<sup>[53]</sup> 除了对模型进行离线评估之外, 还通过互联网发布调查问卷收集了 102 份来自参与在线课程的学生们的有效反馈。Shi 等<sup>[59]</sup> 进行了一项对照实验, 分别收集了来自使用基于多维知识图谱的学习路径生成算法的测试组用户和使用基于一维知识图谱的学习路径生成算法的控制组用户对推荐结果的评分和调查问卷, 以验证基于多维知识图谱的学习路径生成算法的效果。

用户研究作为评估个性化学习资源推荐系统的另一重要实验方式, 具有能够直接了解用户需求、偏好和行为的优点。通过直接观察用户行为和听取他们的反馈, 可以获取更可靠

的数据和见解,有助于提高推荐系统的用户体验和满意度。然而,用户研究也存在一些缺点,如实验过程需要大量时间、人力和资源投入,增加了实验评估的成本和复杂性。此外,用户研究的实验方法可能存在受限于用户案例过少而无法泛化的问题。

### 3.3.4 总结分析

不同的实验方式各有利弊,且适用于不同的特定场景。通过对上述3种实验方式的详细分析,本节对不同实验方式的优缺点进行总结,如表2所列。

表2 常用实验方式的优缺点比较

Table 2 Comparison of advantages and disadvantages of common experimental methods

实验方式	优点	缺点
离线评估	数据获取方便,安全性高,可重复性好	可靠性不足,缺乏实时性
在线评估	实时性强,可信度高	成本较高,需要用户量基础
用户研究	直接了解用户需求、偏好和行为	成本较高,用户案例过少而无法泛化

综上所述,选择适合的实验方式需要综合考虑研究目的、资源限制和实际可行性。在实际应用中,可以根据具体情况综合运用离线评估、在线评估和用户研究等方法,以获得全面而准确的评估结果,从而指导模型的优化。

## 4 局限性分析

基于深度学习的学习资源推荐系统尽管在提升个性化推荐性能和优化用户学习体验等方面取得了显著成效,但在实际应用中仍然存在一些局限性。本章将探讨当前基于深度学习的学习资源推荐系统所面临的主要局限性,具体包括对场景特性的考虑不足以及推荐算法自身的开放性问题两个方面。

### 4.1 对教育领域特性的考虑不足

在当前的研究中,大多数方法直接沿用其他领域(如电商、多媒体等)的推荐思路,缺乏对在线教育领域独有特性的考虑。具体地,这些方法研究缺乏对学习资源之间的先修后继关系、学习者的知识水平与学习能力等特性的显式考虑,而这些特性对于个性化学习资源推荐至关重要。例如,忽略学习资源之间先修后继关系的推荐方法可能会向未曾接触过“计算机程序设计基础”的学习者推荐高级的编程语言课程,如“Java 程序设计”。Zhang 等<sup>[48]</sup>将预训练好的基础推荐模型直接应用于课程推荐,未能考虑课程之间的先修后继关系等场景特性。此外,针对两位历史学习序列完全一致但学习成绩存在显著差异的学习者,现有的推荐方法由于未考虑学习者的知识水平与学习能力感知,生成的课程推荐列表仍是一致的,这明显是不恰当的。例如,Zhang 等<sup>[5]</sup>提出的 KGAN 直接建模学习者与课程历史交互行为数据中隐含的个性化偏好,忽视了对学习者知识水平的感知。目前,仅有少数研究<sup>[8,32]</sup>考虑了个性化学习资源推荐的场景特性,但这些研究的融合方式过于简单,仍有待提升。

### 4.2 受制于推荐算法自身的开放性问题

目前的基于深度学习的个性化学习资源推荐研究还受制于推荐算法自身的开放性问题,如冷启动、可解释性、隐私保护等。

冷启动问题涉及到在系统缺乏足够学习者行为数据的情况下如何有效地进行推荐。对于新注册的学习者,推荐系统需要在几乎没有任何关于学习者学习偏好和能力数据的情况下,推荐适合其学习的资源。对于新引入的学习资源,如何在缺乏先前学习者与学习资源交互数据的情况下有效地将其推荐给合适的学习者也是一大挑战。近年来,冷启动问题的解决策略主要分为数据驱动和方法驱动两大类<sup>[60]</sup>。数据驱动策略利用额外数据源增强推荐系统的信息丰富性,包括基于社交网络的算法和跨域推荐算法等。方法驱动策略通过算法创新提高推荐系统的智能化和准确性,包括基于元学习的算法和基于图的随机游走的算法等。还有的方法结合了传统算法和前沿算法的优点,如 Liu 等<sup>[61]</sup>提出的 HRS-DC。该研究尝试从辅助信息中提取隐式信息,构造了融合辅助信息的新交互矩阵,这在一定程度上解决了冷启动问题。尽管这些解决策略在应对冷启动问题上取得了进展,但它们也暴露出一些局限性。数据驱动策略面临着数据质量以及数据隐私等问题,而方法驱动策略常因计算资源需求高、大规模数据处理效率低以及实现复杂度高而受限。

可解释推荐的核心在于向用户提供清晰、明确的推荐理由,这能够增强用户对系统的信任与满意度。然而,基于深度学习的个性化学习资源推荐系统往往难以提供直观的解释,面临着如何提高可解释性的挑战。为了提高推荐的可解释性,现有研究主要采用两种方法,分别是嵌入式解释方法和事后处理解释方法<sup>[62]</sup>。嵌入式解释方法将解释能力内置于推荐系统之中,例如 Chen 等<sup>[63]</sup>提出的一种基于互注意力机制的多任务学习模型。具体而言,该研究设计了一个编码器-选择器-解码器架构,其中选择器被用来控制跨任务的知识传递,为两个任务提供交叉知识。该研究紧密结合了推荐任务和解释任务,在一定程度上提高了推荐系统的可解释性。而事后处理解释方法则在推荐之后生成解释,例如 Chen 等<sup>[64]</sup>提出的可以在推荐后生成解释语句的层次化序列到序列模型。然而,这些可解释推荐方法仍有局限性。嵌入式解释方法因解释与推荐的高度耦合而缺乏灵活性;此外,这种方法也面临着保证解释质量的挑战。而事后处理解释方法可能会丢失推荐模型所包含的深层次信息。同时,基于预定义模版的事后处理解释方法的解释多样性和个性化程度有限,易导致用户体验的单一化。

推荐系统通过分析用户的行为数据与偏好设置来提供个性化内容推荐,这通常涉及大量敏感信息。因此,保护用户的隐私信息,确保对用户数据的使用不侵犯用户的隐私权利,并防止未经授权的访问、泄露或滥用,成为了包括学习资源推荐研究在内的所有推荐系统面临的重要挑战。针对个性化学习资源推荐中的隐私保护问题,可以借鉴差分隐私<sup>[65]</sup>、同态加密<sup>[66]</sup>以及联邦学习<sup>[67]</sup>等推荐系统中常用的隐私保护技术。差分隐私技术通过在查询结果中加入噪声以实现隐私保护;同态加密技术是一种允许直接在密文上进行计算,并确保计算结果的安全性的加密技术;联邦学习通过在客户端进行本地计算并只共享中间数据,降低了数据泄露风险。虽然现有的隐私保护技术为推荐系统提供了必要的安全保障,但是它们可能会对系统的推荐准确性造成消极

影响。此外,这些技术对计算和存储资源的高需求,以及对稳定且高速通信连接的依赖,也是其在实际应用当中所存在的局限性。

## 5 未来研究方向

本章旨在探讨当前学习资源推荐研究的局限性,并提出未来可能的发展方向。将从攻克当前学习资源推荐研究所面临的局限性以及融合外部新兴技术两个角度出发,探讨未来学习资源推荐研究可能的前沿方向。

### 5.1 对当前局限性的攻克

基于第4章的局限性分析,本节将从考虑先修后继关系、面向多类型对象、可解释性、隐私保护以及跨领域等方面着手,探讨如何攻克当前的局限性,并推动学习资源推荐研究向更广阔和更具前瞻性的方向发展。

#### 5.1.1 考虑先修后继关系的推荐研究

考虑学习资源的先修后继关系对学习资源推荐的研究与发展至关重要。在教育领域,满足先修后继关系约束的学习资源推荐可以保障学习者学习的合理性与有效性<sup>[68]</sup>。然而,当前的学习资源推荐方法研究仅通过建模领域知识图谱来引入其中包含的学习资源之间先修后继关系的语义知识<sup>[5,6,32,45]</sup>。在这种建模方式中,知识图谱上其他类型的关系信息会稀释先修后继关系的语义知识,其本质上是一种隐式的先修后继关系语义集成方式。此外,据本文统计,在中国最大的MOOC平台学堂在线上<sup>[49]</sup>,只有0.063725%的知识点对被专家明确标记了先修后继关系。这一观察表明在真实场景中,这种重要的先修后继关系信息是严重缺失的。然而,手动标注缺失的先修后继关系需要大量的领域专家知识,并且是一项劳动密集型的任务。因此,如何在推荐过程中显式且巧妙地引入学习资源之间的先修后继关系,如何自动且精准地实现先修后继关系的补全或预测,将是未来极具实际价值意义的研究方向。

#### 5.1.2 面向多类型对象的推荐研究

当前的学习资源推荐主要关注学习者、课程等单一类型的推荐对象与待推荐对象。然而,在实际的教育场景中,学习者可能不仅需要单一类型的学习资源推荐,而是需要包含了多种类型的学习资源捆绑包推荐<sup>[69-70]</sup>,以保障知识学习的系统性与合理性。同时,在真实学习场景中,学习者通常是以学习共同体的形式存在。面向一群具有相似学习偏好与学习行为的学习者群组提供合适的学习资源推荐,亦是实现在线教育中资源共享的重要机制<sup>[71-72]</sup>。此外,除了面向学习者,针对教师的个性化学习资源推荐,能够有效帮助教师进行课程教学改革,同样是一个具有可观前景的研究方向。

#### 5.1.3 可解释性推荐研究

可解释性推荐研究旨在解决推荐系统中“为什么”的问题,要求推荐模型不仅能为用户生成推荐结果,还要提供合理的推荐理由<sup>[73]</sup>。基于因果推断的可解释性推荐研究<sup>[74]</sup>旨在从用户层面和交互层面探索因果关系对用户行为的驱动机理,从而赋予推荐过程与推荐结果以一定的可解释性。例如,Zheng等<sup>[75]</sup>设计了一种分离兴趣与从众性的因果嵌入框架,基于真实观察到的两个关于受欢迎程度的因果关系,对用户

的历史交互数据集进行特定因果感知的划分,并通过差异性任务互斥建模,实现用户真实兴趣与从众性特征的分离,从而强化推荐的性能与可解释性。因此,除了因果推断外,如何更好地强化推荐的解释性一直都是当前推荐系统研究中的一个重要课题。

#### 5.1.4 考虑隐私保护的推荐研究

近年来,人们越来越重视个人数据的隐私问题。对于在线学习资源推荐系统来说,分析数据并从中获取偏好时,需要收集学习者的个人信息、社交信息、学习水平等数据,因此在使用时更要额外注意学习者隐私信息保护,避免隐私泄露。现有的研究开始尝试使用联邦学习的方式来缓解隐私数据泄露的问题。基于联邦学习的推荐系统研究期望在数据不移动的前提下协同训练一个全局共享的模型<sup>[67]</sup>。在该过程中,用户的原始数据始终保存在用户的客户端本地,不会暴露给服务器或其他设备,服务端和用户之间通过共享加密等方式进行模型的训练与优化。然而,目前对于用户隐私保护的推荐系统研究仍存在较多的研究空白,亟需研究推进。

#### 5.1.5 跨领域的推荐研究

随着推荐系统在教育领域的广泛应用,跨领域的推荐研究变得尤为重要。这一领域的研究旨在利用不同领域的知识和技术,为用户提供更加多样化和个性化的推荐服务,以满足用户不同领域的需求<sup>[76-78]</sup>,例如将职位推荐和书籍推荐的领域知识相互结合,实现跨领域的知识迁移。通过深入挖掘不同领域的知识,可以提高推荐系统对用户需求的理解和匹配度,为用户提供更加全面和精准的推荐服务。跨领域的推荐研究还可以通过知识迁移来缓解推荐系统的冷启动问题。通过将不同领域的知识进行迁移和共享,可以快速适应新领域的推荐任务,提高推荐系统的泛化能力和效果稳定性。

在未来的研究中,跨领域的推荐研究将面临一系列挑战和机遇。研究者可以探索如何更好地整合不同领域的知识、算法和数据,构建跨领域的推荐模型,以提升推荐系统的推荐结果和用户体验。同时,还可以借助领域专家的知识和经验,深化对跨领域推荐需求的理解,为推荐系统的发展开拓新的研究方向和创新点。

## 5.2 对外部新兴技术的利用与融合

随着智能技术的不断进步和教育领域的不断发展,对外部新兴技术的利用与融合将成为推动学习资源推荐系统进一步发展的重要动力。本节将探讨如何将多模态感知、时序知识图谱以及大语言模型等外部新兴技术与推荐系统相融合,以提升学习资源推荐的个性化、准确性和效能。

### 5.2.1 考虑多模态的推荐研究

近年来,多模态融合通过建模与集成不同模态数据中蕴含的特征信息及其关联关系,能够有效地强化表征学习的质量,以增强各类深度学习任务的效果,从而成为各大研究领域的研究热点之一<sup>[79-80]</sup>。常见的模态数据包括文字、图像、音频等。在推荐系统研究中引入多模态数据,有助于通过额外的模态信息来辅助对历史用户-物品交互的建模,并捕获到不同模态之间的互补信息,从而强化用户与物品的表征学习质量<sup>[81-82]</sup>。由此可见,如何在学习资源推荐的研究中有效且合适地建模与融合多模态数据,如课程ppt、上课音频等,将是

一个具有可观前景的研究方向。

### 5.2.2 时序知识图谱的集成研究

现有的学习资源推荐方法研究均基于领域知识图谱是静态且完整的前提假设,而实际中这些图谱中的实体及关联信息通常会随着时间进行动态演化<sup>[83-85]</sup>。Jiang等<sup>[86]</sup>在2016年首次提出将知识图谱原有的三元组表示形式扩展为四元组形式,引入了表示三元组有效时间的属性。引入时间属性的图谱被称为时序知识图谱,也称为动态知识图谱。时序知识图谱在学习资源推荐中的集成研究旨在结合时序知识图谱中的时间属性,更好地捕获知识之间的动态演化关系,以提高学习资源推荐的准确性与时效性<sup>[87-88]</sup>。在这一研究方向下,未来可以深入探索如何构建具有实时更新机制的时序知识图谱,并将其丰富的时序语义融入到推荐模型中,为学习者提供更加实时且具有前瞻性的学习资源推荐。

### 5.2.3 大语言模型赋能的推荐研究

最近,以 ChatGPT 为代表的大语言模型的推出,让人们把研究的眼光转向将大语言模型与各项深度学习任务相结合<sup>[89-91]</sup>。大语言模型所具备的丰富的世界知识、强大的语义理解与上下文推理能力,为推荐任务提供了新的发展方向<sup>[92-93]</sup>。例如,Ren等<sup>[94]</sup>提出了一种基于大语言模型的表征学习框架,通过大语言模型生成用户与物品相关的语义配置描述以强化表征学习的质量。除了利用大语言模型进行辅助文本生成与用户偏好理解之外,还有部分研究尝试将大语言模型直接作为推荐模型,通过其推理能力直接生成推荐结果。例如,Liu等<sup>[95]</sup>直接将 ChatGPT 用作通用推荐模型,探索其将从大规模语料库中获取的大量语义和世界知识转移到推荐场景中的潜力,在评分预测、序列化推荐、协同过滤推荐、解释生成、评论总结5种推荐任务上进行了推荐性能的实验评估。Zhu等<sup>[92]</sup>通过软硬提示混合策略微调一个协同大语言模型用于推荐任务,实现大语言模型范式与ID范式的深度融合,使得模型同时捕获用户/物品的协同信息与内容信息。由此可见,大语言模型的影响正逐渐引领着推荐系统研究的变革。因此,如何有效且巧妙地引入大语言模型技术来赋能学习资源推荐,亦是一个十分具有前景的研究方向。

**结束语** 本文以“如何实现个性化学习资源推荐”和“如何实现对推荐结果的评估”两个问题为导向,对基于深度学习的个性化学习资源推荐的研究进展进行了多维度、多层次、系统性的回顾与总结分析。首先,同时从场景特性、推荐目标、深度学习技术、边信息集成方式以及推荐模式5个维度对学习资源的个性化推荐过程进行分类与总结,以解答“如何实现个性化学习资源推荐”的问题。其次,从数据集、评估指标以及实验方式3个方面对推荐结果的评估过程进行归纳与比较,并提供所有开源数据集的统一下载链接,以解答“如何实现对推荐结果的评估”的问题。最终,对学习资源推荐方法研究当前所面临的局限性进行深入讨论,并从对当前局限性的攻克以及对外部新兴技术的利用与融合两个方面对未来研究方向进行展望。本文对基于深度学习的个性化学习资源推荐研究的总结和探讨,旨在为计算机与教育学交叉领域相关的人员提供参考和帮助。

## 参 考 文 献

- [1] ZHENG Q H, DONG B, QIAN B Y, et al. Research status and development trend of smart education[J]. Journal of Computer Research and Development, 2019, 56(1): 209-224.
- [2] CHEN X, SUN Y H, DING C Q, et al. A knowledge graph-enhanced method of recommending online courses[J]. Software Guide, 2022, 21(1): 9-14.
- [3] NABIZADEH A H, LEAL J P, RAFSANJANI H N, et al. Learning path personalization and recommendation methods: A survey of the state-of-the-art[J]. Expert Systems with Applications, 2020, 159: 113596.
- [4] ZHONG L, WEI Y, YAO H, et al. Review of deep learning-based personalized learning recommendation[C]// Proceedings of the 2020 11th International Conference on E-Education, E-Business, E-Management, and E-Learning. 2020: 145-149.
- [5] ZHANG H, SHEN X, YI B, et al. KGAN: Knowledge grouping aggregation network for course recommendation in MOOCs[J]. Expert Systems with Applications, 2023, 211: 118344.
- [6] DENG W, ZHU P, CHEN H, et al. Knowledge-aware sequence modelling with deep learning for online course recommendation [J]. Information Processing & Management, 2023, 60(4): 103377.
- [7] WANG C, ZHU H, ZHU C, et al. Personalized employee training course recommendation with career development awareness [C]// Proceedings of the Web Conference. 2020: 1648-1659.
- [8] WANG X, MA W, GUO L, et al. HGNN: Hyperedge-based graph neural network for MOOC course recommendation[J]. Information Processing & Management, 2022, 59(3): 102938.
- [9] GONG J, WANG S, WANG J, et al. Attentional graph convolutional networks for knowledge concept recommendation in MOOCs in a heterogeneous view [C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. Virtual Event China: ACM, 2020: 79-88.
- [10] DONG Y F, WANG Y C, DONG Y, et al. A review of online learning resources recommendation [J]. Journal of Computer Applications, 2023, 43(6): 1655.
- [11] YU P, LIU X Y, CHENG H, et al. A review of online course recommendation systems [J]. Journal of Computer Engineering & Applications, 2023, 59(22): 1-14.
- [12] XU C, HUANG H, YING X, et al. HGNN: Hierarchical graph neural network for predicting the classification of price-limit-hitting stocks[J]. Information Sciences, 2022, 607: 783-798.
- [13] ZHOU J F, DU Y F, SONG B Y, et al. A MOOC video recommendation method based on meta-path attention mechanism[J]. Journal of Computer Applications, 2022, 42(6): 1808.
- [14] TANG C L, LIAO J, WANG H C, et al. Conceptguide: Supporting online video learning with concept map-based recommendation of learning path [C]// Proceedings of the Web Conference. 2021: 2757-2768.
- [15] WU S X, LUO X Z, ZHONG M S, et al. MOOC-DR-VSI: A MOOC resource dynamic recommendation model fusing video subtitles information[J]. Journal of Computer Research and De-

- velopment, 2024, 61(2):470-480.
- [16] JIANG C M, FENG J, SUN X, et al. Personalized exercise recommendation algorithm based on knowledge point hierarchical graph [J]. *Computer Engineering and Applications*, 2018, 54(10):229-235.
- [17] ZHOU Y T, LI Q S, CHU H, et al. Knowledge point recommendation method based on static and dynamic learning demand perception[J/OL]. <https://www.jos.org.cn/jos/article/abstract/6962?st=search>.
- [18] ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. *Psychological Review*, 1958, 65(6):386.
- [19] SEDHAIN S, MENON A K, SANNER S, et al. AutoRec: Autoencoders meet collaborative filtering[C]// *Proceedings of the 24th International Conference on World Wide Web*, 2015:111-112.
- [20] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C] // *Proceedings of the 26th International Conference on World Wide Web*, 2017:173-182.
- [21] ZHAO Z, YANG Y, LI C, et al. GuessUNeed: Recommending courses via neural attention network and course prerequisite relation embeddings[J]. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 2020, 16(4):1-7.
- [22] LIN Y, FENG S, LIN F, et al. Multi-scale reinforced profile for personalized recommendation with deep neural networks in MOOCs[J]. *Applied Soft Computing*, 2023, 148:110905.
- [23] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. *Neural Computation*, 1989, 1(4):541-551.
- [24] ZHENG L, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation[C]// *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, 2017:425-434.
- [25] SHU J, SHEN X, LIU H, et al. A content-based recommendation algorithm for learning resources[J]. *Multimedia Systems*, 2018, 24(2):163-173.
- [26] WANG J, XIE H, AU O, et al. Attention-based CNN for personalized course recommendations for MOOC learners [C] // *2020 International Symposium on Educational Technology (ISET)*. IEEE, 2020:180-184.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8):1735-1780.
- [28] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[C]// *NIPS 2014 Workshop on Deep Learning*, 2014.
- [29] DANG Y, YANG E, GUO G, et al. Uniform sequence better: Time interval aware data augmentation for sequential recommendation[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*, 2023:4225-4232.
- [30] ZHANG Q, LI Y, ZHANG G, et al. A recurrent neural network-based recommender system framework and prototype for sequential E-learning[C]// *Developments of Artificial Intelligence Technologies in Computation and Robotics: Proceedings of the 14th International FLINS Conference (FLINS 2020)*, 2020:488-495.
- [31] ZHOU Y, HUANG C, HU Q, et al. Personalized learning full-path recommendation model based on LSTM neural networks [J]. *Information Sciences*, 2018, 444:135-152.
- [32] BAN Q, WU W, HU W, et al. Knowledge-enhanced multi-task learning for course recommendation [C]// *International Conference on Database Systems for Advanced Applications*. Cham: Springer International Publishing, 2022:85-101.
- [33] BERG R V, KIPF T N, WELLING M. Graph convolutional matrix completion[C]// *ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2018.
- [34] HE X, DENG K, WANG X, et al. Lightgcn: Simplifying and powering graph convolution network for recommendation[C]// *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2020:639-648.
- [35] ZHU Y, LU H, QIU P, et al. Heterogeneous teaching evaluation network based offline course recommendation with graph learning and tensor factorization[J]. *Neurocomputing*, 2020, 415:84-95.
- [36] DAI J, LI Q S, CHU H, et al. Breakthrough in smart education: course recommendation system based on graph learning [J]. *Journal of Software*, 2022, 33(10):3656-3672.
- [37] FENG Y, YOU H, ZHANG Z, et al. Hypergraph neural networks[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019:3558-3565.
- [38] XIA L, HUANG C, XU Y, et al. Hypergraph contrastive collaborative filtering [C] // *Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2022:70-79.
- [39] LIU X, ZHANG F, HOU Z, et al. Self-supervised learning: Generative or contrastive[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 35(1):857-876.
- [40] ZHOU Y T, LI Q S, CHU H, et al. Inherent-attribute-aware dual-graph autoencoder for rating prediction[J]. *Journal of Information and Intelligence*, 2024, 2(1):82-97.
- [41] HINTON G E, ZEMEL R. Autoencoders, minimum description length and Helmholtz free energy[C]// *Advances in Neural Information Processing Systems*, 1993.
- [42] YU M, QUAN T, PENG Q, et al. A model-based collaborate filtering algorithm based on stacked AutoEncoder [J]. *Neural Computing and Applications*, 2022, 1:1-9.
- [43] CHEN X, SHEN J, XIA W, et al. Set-to-sequence ranking-based concept-aware learning path recommendation[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*, 2023:5027-5035.
- [44] CAO Y, WANG X, HE X, et al. Unifying knowledge graph learning and recommendation: Towards a better understanding of user preferences[C]// *World Wide Web Conference*, 2019:151-161.
- [45] YANG S, CAI X. Bilateral knowledge graph enhanced online course recommendation [J]. *Information Systems*, 2022, 107:102000.

- [46] ALATRASH R, CHATTI M, AIN Q, 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.
- [47] JING X, TANG J. Guess you like: course recommendation in MOOCs[C] // *Proceedings of the International Conference on Web Intelligence*. 2017: 783-789.
- [48] ZHANG J, HAO B, CHEN B, et al. Hierarchical reinforcement learning for course recommendation in MOOCs[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2019: 435-442.
- [49] YU J, LUO G, XIAO T, et al. MOOCcube: 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.
- [50] LIU K, ZHAO X, TANG J, 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.
- [51] PANDEY S, SRIVASTAVA J. RKT: relation-aware self-attention for knowledge tracing[C] // *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. 2020: 1205-1214.
- [52] ZHU R, ZHANG D, HAN C, et al. Programming knowledge tracing: A comprehensive dataset and a new model[C] // *2022 IEEE International Conference on Data Mining Workshops (ICDMW)*. IEEE, 2022: 298-307.
- [53] ZHANG S, HUI N, ZHAI P, et al. A fine-grained and multi-context-aware learning path recommendation model over knowledge graphs for online learning communities[J]. *Information Processing & Management*, 2023, 60(5): 103464.
- [54] YANG Y, ZHANG C, SONG X, et al. Contextualized knowledge graph embedding for explainable talent training course recommendation[J]. *ACM Transactions on Information Systems*, 2023, 42(2): 1-27.
- [55] WU Z, LI M, TANG Y, et al. Exercise recommendation based on knowledge concept prediction[J]. *Knowledge-Based Systems*, 2020, 210: 106481.
- [56] ZHU T Y, HUANG Z Y, CHEN E H, et al. A personalized item recommendation method based on cognitive diagnosis[J]. *Chinese Journal of Computers*, 2017, 40(1): 176-191.
- [57] LI Q, XIA W, YIN L, et al. Graph Enhanced Hierarchical reinforcement learning for goal-oriented learning path recommendation[C] // *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*. 2023: 1318-1327.
- [58] LIN Y, FENG S, LIN F, et al. Adaptive course recommendation in MOOCs[J]. *Knowledge-Based Systems*, 2021, 224: 107085.
- [59] SHI D, WANG T, XING H, et al. A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning[J]. *Knowledge-Based Systems*, 2020, 195: 105618.
- [60] MAO Q, XIE W C, QIAO Y T, et al. A survey on solutions to the cold start problem in recommendation systems[J/OL]. [https://kns.cnki.net/kcms2/article/abstract?v=dMo7FjsfBlG-uidsWNXWO4mmT72JQeYKOCak-wQ72fGS\\_7Jsg9K97dQv8MEynL4ALLfG034fbZuVQsby223Trfv2JWw2aM5Wk0414n-dphec7JoT8\\_uQ3FAHwwg64mB0LFZnqxEARZY8h00d7bRv9-s\\_6a8-Yw2NspVX6BAQHivFGBAc2bROhn-UAAxlcOND5xmSFb6r6fi4=&uni-platform=NZKPT&language=CHS](https://kns.cnki.net/kcms2/article/abstract?v=dMo7FjsfBlG-uidsWNXWO4mmT72JQeYKOCak-wQ72fGS_7Jsg9K97dQv8MEynL4ALLfG034fbZuVQsby223Trfv2JWw2aM5Wk0414n-dphec7JoT8_uQ3FAHwwg64mB0LFZnqxEARZY8h00d7bRv9-s_6a8-Yw2NspVX6BAQHivFGBAc2bROhn-UAAxlcOND5xmSFb6r6fi4=&uni-platform=NZKPT&language=CHS).
- [61] LIU Z P, YIN W Z, WANG W S, et al. HRS-DC: A hybrid recommendation model based on deep learning[J]. *Journal of Computer Engineering & Applications*, 2020, 56(14): 169-175.
- [62] GAO G S. A survey of explainability methods in explainable recommendation models[J/OL]. [https://kns.cnki.net/kcms2/article/abstract?v=dMo7FjsfBlFi5gMu4gAOeyxNzhLTueCpFe\\_o72pI8-JsUkKBZKe-pd-avfhJt06MgWxPtDecmooWm-zZCDrzTZcfEypppgPfrB9FP-ybixhAHhLZer1l7GLtSoxUuEeflEi53Hk05Kc1t46E3p767ppdf\\_ZnO1Ml8P1QnsReY9sr9w1UrKzTRhbUFDF2i6Wlm&uniplatform=NZKPT&language=CHS](https://kns.cnki.net/kcms2/article/abstract?v=dMo7FjsfBlFi5gMu4gAOeyxNzhLTueCpFe_o72pI8-JsUkKBZKe-pd-avfhJt06MgWxPtDecmooWm-zZCDrzTZcfEypppgPfrB9FP-ybixhAHhLZer1l7GLtSoxUuEeflEi53Hk05Kc1t46E3p767ppdf_ZnO1Ml8P1QnsReY9sr9w1UrKzTRhbUFDF2i6Wlm&uniplatform=NZKPT&language=CHS).
- [63] CHEN Z, WANG X, XIE X, et al. Co-attentive multi-task learning for explainable recommendation[C] // *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence*. 2019: 2137-2143.
- [64] CHEN H, CHEN X, SHI S, et al. Generate natural language explanations for recommendation[J]. *arXiv*: 2101.03392, 2021.
- [65] DWORK C, MCSHERRY F, NISSIM K, et al. Calibrating noise to sensitivity in private data analysis[C] // *Theory of Cryptography: Third Theory of Cryptography Conference*. New York: Springer Berlin Heidelberg, 2006: 265-284.
- [66] TANG Q, WANG J. Privacy-preserving context-aware recommender systems: Analysis and new solutions[C] // *Computer Security--ESORICS 2015: 20th European Symposium on Research in Computer Security*. Vienna: Springer International Publishing, 2015: 101-119.
- [67] LIU Y X, CHEN H, LIU Y H, et al. Privacy-preserving techniques in federated learning[J]. *Journal of Software*, 2022, 33(3): 1057-1092.
- [68] ZHOU J, JIANG G, DU W, et al. Profiling temporal learning interests with time-aware transformers and knowledge graph for online course recommendation[J]. *Electronic Commerce Research*, 2023, 23(4): 2357-2377.
- [69] ZHAO S, WEI W, ZOU D, et al. Multi-view intent disentangle graph networks for bundle recommendation[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. ACM, 2022: 4379-4387.
- [70] MA Y, HE Y, ZHANG A, et al. Crosscbr: Cross-view contrastive learning for bundle recommendation[C] // *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. ACM, 2022: 1233-1241.
- [71] ZHANG J, YANG X, SONG W, et al. Survey on learning communities in online education environment[J]. *Journal of Software*, 2023, 33(11): 5058-5083.
- [72] WU X, XIONG Y, ZHANG Y, et al. Consrec: Learning consensus behind interactions for group recommendation[C] // *Proceedings of the ACM Web Conference*. ACM, 2023: 240-250.
- [73] LIN B, CECCHI G, BOUNEFFOUF D. Psychotherapy AI com-

- panion with reinforcement learning recommendations and interpretable policy dynamics[C]//Companion Proceedings of the ACM Web Conference 2023. 2023;932-939.
- [74] WANG W,ZHANG Y,LI H,et al.Causal recommendation: Progresses and future directions[C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM,2023;3432-3435.
- [75] ZHENG Y,GAO C,LI X,et al. Disentangling user interest and conformity for recommendation with causal embedding[C]//Proceedings of the Web Conference. ACM,2021;2980-2991.
- [76] MA H,XIE R,MENG L,et al. Triple sequence learning for cross-domain recommendation[J]. ACM Transactions on Information Systems,2024,42(4):1-29.
- [77] ZHAO Y,LI C,PENG J,et al. Beyond the overlapping users: cross-domain recommendation via adaptive anchor link learning [C]//Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2023;1488-1497.
- [78] HUAN Z,LI A,ZHANG X,et al. SAMD: An industrial framework for heterogeneous multi-scenario recommendation[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2023;4175-4184.
- [79] HU Z, YE A N, HOSSEINI KHORASGANI S, et al. AdaCLIP: Towards pragmatic multimodal video retrieval[C]//Proceedings of the 31st ACM International Conference on Multimedia. ACM,2023;5623-5633.
- [80] WANG L,ZHANG C,XU H,et al. Cross-modal contrastive learning for multimodal fake news detection[C]//Proceedings of the 31st ACM International Conference on Multimedia. ACM, 2023;5696-5704.
- [81] ZHOU X,SHEN Z. A tale of two graphs:Freezing and denoising graph structures for multimodal recommendation[C]//Proceedings of the 31st ACM International Conference on Multimedia. ACM,2023;935-943.
- [82] WEI W, HUANG C, XIA L, et al. Multi-modal self-supervised learning for recommendation[C]//Proceedings of the ACM Web Conference. ACM,2023;790-800.
- [83] PAN S,LUO L,WANG Y,et al. Unifying large language models and knowledge graphs: A roadmap [J]. arXiv: 2306.08302v2,2023.
- [84] XU Y,OU J,XU H,et al. Temporal knowledge graph reasoning with historical contrastive learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2023;4765-4773.
- [85] ZHANG M, XIA Y, LIU Q, et al. Learning latent relations for temporal knowledge graph reasoning[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics(Volume 1: Long Papers). 2023;12617-12631.
- [86] JIANG T, LIU T, GE T, et al. Towards time-aware knowledge graph completion[C]//Proceedings of the 26th International Conference on Computational Linguistics. 2016;1715-1724.
- [87] ZHAO Y, WANG X, CHEN J, et al. Time-aware path reasoning on knowledge graph for recommendation[J]. ACM Transactions on Information Systems, 2022, 41(2):1-26.
- [88] ZHANG M, XIA Y, LIU Q, et al. Learning long-and short-term representations for temporal knowledge graph reasoning[C]//Proceedings of the ACM Web Conference. ACM, 2023; 2412-2422.
- [89] OUYANG L, WU J, JIANG X, et al. Training language models to follow instructions with human feedback[J]. Advances in Neural Information Processing Systems, 2022, 35:27730-27744.
- [90] TOUVRON H, LAVRIL T, IZACARD G, et al. Llama: Open and efficient foundation language models [J]. arXiv: 2302.13971, 2023.
- [91] ZENG A, LIU X, DU Z, et al. GLM-130B: An open bilingual pre-trained model[C]//The Eleventh International Conference on Learning Representations. 2022.
- [92] ZHU Y, WU L, GUO Q, et al. Collaborative large language model for recommender systems[C]//Proceedings of the ACM Web Conference. ACM, 2024.
- [93] WU L, QIU Z, ZHENG Z, et al. Exploring large language model for graph data understanding in online job recommendations [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2024, 38(8):9178-9186.
- [94] REN X, WEI W, XIA L, et al. Representation learning with large language models for recommendation[C]//Proceedings of the ACM Web Conference. ACM, 2024.
- [95] LIU J, LIU C, LV R, et al. Is chatgpt a good recommender? a preliminary study[J]. arXiv:2304.10149, 2023.



**ZHOU Yangtao**, born in 1998, postgraduate, is a member of CCF (No. J4627G). His main research interests include recommendation system, educational big data and knowledge graph.



**CHU Hua**, born in 1977, Ph.D, associate professor, is a member of CCF (No. K8691M). Her main research interests include recommendation system, educational big data, object-oriented programming and intelligent software engineering.

(责任编辑:柯颖)