

# 突破智慧教育：基于图学习的课程推荐系统\*

歹杰, 李青山, 褚华, 周洋涛, 杨文勇, 卫彪彪



(西安电子科技大学 计算机科学与技术学院, 陕西 西安 710071)

通信作者: 李青山, E-mail: qshli@mail.xidian.edu.cn

**摘要:** 近年来, 随着互联网技术的迅猛发展, 以慕课(MOOC)为代表的在线教育平台得到广泛普及. 为助力“因材施教”的个性化智慧教育, 以推荐算法为代表的人工智能技术受到了学术界与工业界的普遍关注. 虽然在电子商务等领域获得了成功应用, 但推荐算法与在线教育融合时仍面临严峻挑战: 现有算法对隐式交互数据的挖掘不充足, 推荐背后的知识指导作用不明显, 面向实践的推荐系统软件有缺失. 对此, 设计了一套面向工业化场景的智慧课程推荐系统: (1) 提出基于图卷积神经网络的推荐引擎, 将“用户-课程”隐式交互数据建模为异构图; (2) 将课程知识信息融入“用户-课程”异构图, 深入挖掘了“用户-课程-知识”关联关系; (3) 设计了高效的在线推荐系统, 实现了“预处理-召回-离线排序-在线推荐-结果融合”的多段流水线原型, 不仅能够快速响应课程推荐请求, 更能有效缓解推荐算法落地的最大障碍——冷启动问题. 最后, 基于真实课程学习平台数据集, 以对比实验表明了离线推荐引擎相比其他主流推荐算法的先进性, 并基于两个典型用例分析验证了在线推荐系统面临工业场景需求的可用性.

**关键词:** 个性化教育; 图卷积神经网络; 在线推荐系统; 机器学习

**中图法分类号:** TP18

中文引用格式: 歹杰, 李青山, 褚华, 周洋涛, 杨文勇, 卫彪彪. 突破智慧教育: 基于图学习的课程推荐系统. 软件学报, 2022, 33(10): 3656–3672. <http://www.jos.org.cn/1000-9825/6629.htm>

英文引用格式: Dai J, Li QS, Chu H, Zhou YT, Yang WY, Wei BB. Breakthrough in Smart Education: Course Recommendation System Based on Graph Learning. Ruan Jian Xue Bao/Journal of Software, 2022, 33(10): 3656–3672 (in Chinese). <http://www.jos.org.cn/1000-9825/6629.htm>

## Breakthrough in Smart Education: Course Recommendation System Based on Graph Learning

DAI Jie, LI Qing-Shan, CHU Hua, ZHOU Yang-Tao, YANG Wen-Yong, WEI Biao-Biao

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

**Abstract:** With the rapid development of Internet technology, online course learning platforms like MOOCs have gained wide popularity in recent years. In order to facilitate the personalized smart education of “teach students in accordance with their aptitude”, artificial intelligence technologies, represented by recommendation algorithms, have been widely focused by communities of academia and industry. Although it has been successfully applied in e-commerce and other fields, the integration of recommendation algorithms into online education scenarios still faces severe challenges: Existing algorithms are not competent in mining implicit interactives, guidance from knowledge towards recommendation is not effective, and there are still few sights on practical recommendation system software. Therefore, an intelligent course recommendation system is proposed for industrial scenarios, which includes: (1) an offline recommendation engine based on graph convolutional neural network, modeling the “user-course” implicit interaction behavior as a heterogeneous graph, and extracting course knowledge information to guide the model learning and training. Therefore, the relationship

\* 基金项目: 国家自然科学基金(61972300, 61902288, U21B2015); 陕西省自然科学基金基础研究计划(2020JQ-300); 国家重点研发计划(2019YFB1406404); 中国科学院战略性先导科技专项(C类)(XDC05040100)

本文由“智慧信息系统新技术”专题特约编辑邢春晓研究员、王鑫教授、张勇副研究员、于戈教授推荐.

收稿时间: 2021-07-20; 修改时间: 2021-08-30, 2021-12-24; 采用时间: 2022-01-14; jos 在线出版时间: 2022-02-22

like “user-course-knowledge” can be fully and deeply mined; (2) an efficient online recommendation system prototype based on multi-stage pipeline of “preprocess-recall-offline sort-online recommend-result fuse”. Besides quickly responding to course recommendation requests, it can effectively alleviate the major obstacle to recommender systems, the cold start problem. Finally, based on a course learning dataset from real platform, extensive experiments are conducted to show that the proposed offline recommendation engine is competitive with other mainstream recommendation algorithms. And based on the analysis of two typical use cases, the usability of the proposed online recommendation system when facing industrial needs is verified.

**Key words:** personalized education; graph convolutional network; online recommendation system; machine learning

第四次工业革命以来, 科学技术飞速发展, 领域知识快速迭代, 在线教育已成为构建终身学习型社会的关键途径。从 20 世纪 70 年代计算机在线教育方兴未艾, 到学堂在线等慕课(MOOC)平台相继涌现, 广大用户的学习选择日益增多。然而, 课程资源的丰富带来了“课程过载”这一新难题: 用户从过去的“无课可学”, 变成了如今的“无从学起”。类似的“信息过载”困境在电子商务、多媒体内容等领域早已有之, 而推荐系统(recommender system)能够实现高效的信息过滤, 大大缓解了过载难题<sup>[1-3]</sup>。对于在线教育“课程过载”难题, 国内外有多项工作尝试构建课程推荐系统, 实现面向用户学习需求的个性化课程推荐<sup>[4-7]</sup>。但与发展多年的电商/多媒体推荐不同, 在线教育和推荐系统的融合研究尚处初期, 还存在许多重大挑战。

- 挑战之一, 如何充分利用多种交互行为数据, 构建用户学习画像。

关于用户交互数据的利用, 主流的推荐系统都以显式的评分数据(三分制或五分制)作为基础输入<sup>[8]</sup>, 再辅以其他特征数据实现个性化推荐。然而, 在线课程平台一般只有学生的隐式交互行为数据(比如学生对课程的点击、观看时长、收藏评论等), 缺乏显式评分, 主流推荐算法难以直接发挥作用。因此, 如何充分利用多种非评分的交互数据来构建用户学习画像, 是实现智能化课程推荐系统的一个关键。

- 挑战之二, 如何深入挖掘“用户-知识-课程”关联, 以知识主导课程推荐效果。

推荐算法评估除了依靠准确率、召回率等指标<sup>[9]</sup>, 还需要结合应用场景的具体分析, 比如视频推荐中的观看热度分析<sup>[10]</sup>、电子商务推荐中的下单支付分析<sup>[11]</sup>。对在线教育场景而言, 用户希望通过课程学习实现对知识的掌握, 知识应当指导推荐模型训练预测的全过程。因此, 如何对课程蕴含的知识信息进行挖掘, 在知识表征空间中实现表征学习与推荐匹配, 是实现智能化课程推荐的另一个关键之处。

近年来, 工业界和学术界做出了许多课程推荐探索, 但都未能妥善解决以上挑战。一方面, 它们无法充分利用非评分的隐式交互数据。或者将其无视<sup>[6]</sup>, 或者通过简单映射将其转换为数值<sup>[5]</sup>, 造成了信息的损失; 另一方面, 许多课程推荐系统仍沿用了电商和视频推荐算法的设计思想, 以交互热度、用户偏好指导推荐算法训练预测, 忽视了背后关键的知识关联<sup>[12]</sup>。换言之, 系统将难以基于学习认知规律提供课程推荐, 不利于用户知识体系完善, 无益于学习效果提升。

- 除以上研究性挑战外, 课程推荐系统还面临着源自工业场景需求的设计性挑战。

现有课程推荐系统研究大多沿用深度学习思想下的端到端开发模式<sup>[13,14]</sup>, 将课程推荐过程简单划分为“输入-黑盒-输出”这 3 个环节, 核心步骤, 如数据处理、实体表征、输出预测都被包含在了“黑盒”之中。而从软件工程角度分析, 像这样不同步骤的实现模块高度耦合、边界模糊, 将严重损害软件可扩展性、可移植性, 极大地增加了运维成本。事实上, 有许多企业意识到了这些问题, 并按照规范化的数据流水线设计思想, 对推荐系统进行了多阶段划分。例如, YouTube<sup>[15]</sup>首创性地把视频推荐系统划分为预处理、召回和排序这 3 个阶段。其他公司, 如 Facebook<sup>[16]</sup>、Pinsage<sup>[17]</sup>、腾讯<sup>[18]</sup>、淘宝<sup>[11]</sup>也参照这种思想, 指导了推荐系统软件设计和开发, 并通过工业场景实践检验了其可行性。因此, 为满足工业场景下的课程推荐需求, 除了性能突出的课程推荐算法外, 还必须基于多阶段流水线思想实现合理的系统设计。

综上所述, 面向在线教育工业场景设计实践可行的个性化课程推荐系统, 必须解决如下几个主要难题: (1) 如何实现对多种不同交互行为的数据建模, 以方便后续用户向量和课程向量的学习和表示? (2) 如何实现课程知识的建模, 以实现将课程中包含的知识融入向量学习过程中? (3) 如何对课程推荐背后数据流水线进行环节规划和模块切分, 以满足真实在线教育场景对课程推荐的需求?

为解决上述 3 个问题, 本文提出了一种基于图学习的课程推荐系统: (1) 设计了一种针对在线学习隐式交互的建模方法, 将多种用户交互行为建模为异构图, 进而实现用户和课程的表征学习; (2) 提出了一种将知识融入课程向量的图卷积方法, 基于“用户-课程”异构图进行卷积计算, 将节点表征映射至知识空间中, 突出知识对推荐的主导作用; (3) 设计了一种多阶段推荐流水线, 实现了“预处理-召回-离线排序-在线推荐-结果融合”的系统原型, 并有针对性地缓解了冷启动问题, 以满足工业场景的落地需求.

本文的创新贡献如下:

- (1) 数据建模方面, 将不同的用户交互行为构建成为统一的异构图, 作为后续图卷积学习的基础框架, 方便对用户与课程节点展开表征学习;
- (2) 算法设计方面, 将课程知识融入到具有强大表征学习能力的 GNN 深度学习算法中, 实现对“用户-知识-课程”之间关联关系的挖掘;
- (3) 系统架构方面, 设计了面向真实在线教育场景的多阶段推荐流水线, 并开发了对应原型软件, 在重型深度学习和轻型在线推荐之间实现了平衡;
- (4) 实验验证方面, 在真实课程学习数据集上设计了离线推荐引擎的对比实验, 结果表明, 该引擎能够获得与前沿推荐算法相当的优异性能. 此外, 对推荐流水线原型进行了具体案例分析, 结果表明: 该原型能够根据用户的学习画像提供有针对性的课程推荐, 有力地缓解了新用户所面临的冷启动难题, 满足了在线教育场景的实践需求.

## 1 相关工作

### 1.1 推荐算法发展概览

自互联网发明以来, 各类平台软件发展迅速, “信息过载”难题日益严峻, 而推荐算法能够给予有效缓解: 它可以基于用户偏好, 提供个性化信息过滤服务. 推荐算法的典型思想是基于用户 ID 的协同过滤, 以经典算法矩阵分解<sup>[19]</sup>为例, 它将用户 ID 转换为嵌入向量, 通过“用户-项目”交互矩阵的重构, 学习用户偏好表征, 实现推荐预测. 该思想在神经网络出现后仍然流行, 比如刘华锋等人<sup>[20]</sup>指出: 可以基于神经推荐模型实现相似的初始嵌入转换, 对矩阵重建进行深度增强, 同时融入其他辅助信息, 以提升推荐效果.

除了使用 ID 作为用户初始输入, 还有一类协同过滤将历史交互项目作为用户输入, 提供更丰富的语义信息. 代表算法之一为 SVD++<sup>[21]</sup>, 它基于项目嵌入向量的加权平均值来初始化用户, 以进一步改进用户表征. 此后, 研究人员意识到不同交互项目对用户偏好挖掘的贡献不同, 提出了 ACF<sup>[22]</sup>等基于注意力机制的协同过滤算法, 深入挖掘交互项目的贡献度. 值得注意的是: 当我们将“用户-项目”交互数据建模为异构图时, 基于用户/项目 ID 的协同过滤可以视为图上用户相邻节点的信息表征, 这从理论层面解释了推荐性能提升的原因.

随着图学习技术的表征能力得到广泛认可, 基于图学习的推荐算法逐渐成为热门方向. 在此方向做出探索的代表性工作包括 ItemRank<sup>[23]</sup>和 HERec<sup>[24]</sup>, 它们通过异构图表示算法, 对“用户-项目”交互图蕴含的结构信息与用户偏好进行了深入挖掘. 随后出现的图神经网络技术, 特别是图卷积技术, 实现了全新的邻居节点信息聚合编码机制, 进一步提升了模型表征效果<sup>[25,26]</sup>, 而且具有高可解释性与低计算成本. 受此启发, 学者们先后提出了 NGCF<sup>[27]</sup>、GC-MC<sup>[28]</sup>、PinSage<sup>[17]</sup>等图卷积推荐模型, 对“用户-项目”交互图中高阶邻居节点间蕴含的协同过滤信号进行捕捉, 进一步提升了推荐效果. 总之, 作为推荐算法的核心输入, “用户-项目”交互数据是不规则的网格化数据, 显著区别于文本、图像等规则网格化数据. 对此, 循环神经网络、卷积神经网络等主流工具无法适用, 图卷积神经网络则能够实现有针对性的图结构表征学习, 因而图卷积推荐算法成为当前前沿推荐算法之一.

### 1.2 推荐效果的主导因素

一直以来, 用户偏好是推荐算法效果评估的主导因素. 比如, Goldberg 等人<sup>[29]</sup>在 1992 年提出的协同过滤推荐方法, 基于“用户-项目”交互记录, 挖掘用户潜在偏好, 进而向用户提供个性化推荐. 后续出现的机器学习

习推荐方法, 如基于评分矩阵分解得到用户/项目表征向量<sup>[30]</sup>, 以及基于特征交叉实现用户和项目关联预测<sup>[31]</sup>等, 虽然细节各有不同, 但本质上仍然是协同过滤思想的延伸. 近年来, 随着深度学习的广泛应用, 许多新的研究尝试利用神经网络处理“用户-项目”交互记录数据, 提取用户和项目的潜在特征, 并以向量内积<sup>[32]</sup>、神经网络映射<sup>[13]</sup>等方式实现推荐预测. 此外, 冯永等人<sup>[33]</sup>引入了循环神经网络(recurrent neural network)工具, 以处理“用户-项目”交互记录中的时间维度; 赵朋朋等人<sup>[34]</sup>利用类似的循环神经网络捕捉用户偏好的动态变化, 实现面向交互序列的推荐预测. 总体而言, 学术界与工业界提出的许多前沿推荐系统研究, 都在尝试以不同技术深入挖掘用户偏好, 从而提供用户喜欢的内容.

然而, 以用户偏好为主导的推荐方法并不适用于课程推荐. 正如前文所述, 课程推荐系统除了考虑用户对课程的点击等以外, 更要注重用户在学习过程中知识的获取. 这种区别引起了部分研究的注意. 例如, 文献[35]提出了一种基于图神经网络的方法 ACKRec, 不仅学习了“用户-课程”的直接交互关联, 更学习了“用户-课程-知识”的间接知识关联, 能够向用户推荐符合其学习画像的知识概念. 而文献[5]针对企业培训场景提出了一种培训课程推荐系统, 将课程知识标签和“用户-课程”评分共同作为输入信息, 实现了基于深度学习的课程推荐, 以知识的指导作用确保课程的培训效果.

### 1.3 工业场景的推荐需求

推荐系统作为源于互联网应用的研究方向, 一直受到工业界的密切关注. 值得注意的是, 工业界推荐系统研究与学术界存在以下主要差别: (1) 核心输入不同, 工业场景的交互数据以隐式交互数据为主, 而学术研究常用数据集以显式评分数据为主; (2) 设计思想不同, 工业应用推荐系统普遍为多阶段流水线模式, 而学术界推荐系统更多为“端到端”模式. 这些差别导致了学术界的部分研究难以对接工业场景需求.

在核心输入方面, 学术界推荐系统通常采用显式评分数据. 常用数据集如 MovieLens 和 CiaoDVD 等, 提供了大量用户对交互项目的显式评分, 用于后续建模计算. 然而, 工业场景中通常没有足够可用的评分数据. 例如, 在抖音、优酷等视频平台, 用户与视频之间不存在显式评分交互, 只有各类隐式交互, 如点击、留存、收藏等. 即使是淘宝等支持显式评分的平台, 其大部分评分记录也并非来自用户, 而是系统默认评分. 总之, 基于显式评分的推荐方法在这些场景中会受到严重的负面影响. 为克服该难题, 工业界推荐系统通常以隐式交互数据作为核心输入. 例如, Facebook 团队<sup>[36]</sup>提出了一种基于梯度下降树的广告推荐模型, 能够对各类隐式特征信息进行筛选组合, 进而生成离散特征向量, 服务后续点击预测计算. 阿里巴巴团队<sup>[37]</sup>通过深度学习模型融合了用户的购买、点击、浏览等行为数据, 以及用户、商品属性数据, 挖掘用户购物兴趣进化过程, 实现下一次购物预测. 与上述场景类似, 课程推荐平台也是显式评分缺乏, 而隐式交互丰富. 因此, 要设计面向工业场景的课程推荐系统, 必须围绕“用户-课程”隐式交互来展开系统建模.

在设计思想方面, 受到深度学习研究的影响, 学术界的推荐系统大多采用“端到端”的设计模式. 典型方式是: 将复杂的算法实现集成在一个推荐模块中, 提供交互输入, 得到推荐输出. 然而, 工业场景的数据规模远超论文常用数据集, 这会导致深度模型的参数规模爆炸, 产生不切实际的算力需求. 更为严重的是, 这种“端到端”的方式把多项功能实现混在一个“黑盒”里, 模块职责不明, 代码依赖混乱, 严重削弱了系统的可扩展性与灵活性, 不利于后续的软件维护与模块复用. 工业界很早就注意到了这一问题, 并通过多阶段流水线式设计予以解决<sup>[38]</sup>. YouTube<sup>[15]</sup>于 2016 年最早提出了“召回+排序”两阶段数据流水线, 构建了面向百万级数据的漏斗式处理机制. 之后, 工业界推荐系统一直在多阶段流水线基础上改进创新. 针对学术界关注不多的召回阶段, 工业界做出了许多有效的尝试. 例如: Pinsage<sup>[17]</sup>提出了基于图神经网络的高可扩展性推荐系统, 以创新的随机游走负采样策略对召回阶段进行改进; Facebook<sup>[16]</sup>提出了基于双塔神经网络模型的向量采样算法, 提升了召回阶段的数据过滤效率. 此外, 也有企业关注了召回阶段之前的数据预处理阶段. 例如, 百度公司<sup>[39]</sup>提出了一种基于用户请求与广告点击的数据增强机制, 为后续召回构造了更多有效样本. 总之, 多阶段流水线已成为工业界推荐系统设计的基本模式, 对于课程推荐系统而言, 其设计也必须遵循这一规范, 才能确保面向工业化在线教育场景的可行性.

### 1.4 课程推荐相似工作对比

近年来, 推荐算法与智慧教育的结合开始获得学术界的关注. 其中, 与本文研究主题最为接近的工作有两项.

- (1) 研究之一<sup>[40]</sup>面向多种隐式交互行为, 设计了异构图卷积深度推荐模型. 其核心思想在于: 将多种隐式交互行为数据建模为一个无向异构图, 通过图卷积算法挖掘各个行为的语义信息, 实现全面的用户/项目表征学习, 最终计算出推荐结果;
- (2) 研究之二<sup>[41]</sup>针对“用户-课程-知识”关联关系, 设计了基于注意力的图卷积推荐模型. 它综合利用学生、教师、课程、知识等实体信息, 抽取实体之间的语义关联, 并融入交互上下文信息, 在知识空间中建立用户画像, 学习用户课程表征向量, 实现知识概念推荐.

以上两项研究分别从隐式交互利用、知识信息指导两方面缓解了课程推荐面临的主要困境, 但缺乏有机的统一. 相比之下, 本文提出的课程推荐系统同时融合了隐式交互数据利用、“用户-课程-知识”关联挖掘, 实现了更加全面的课程推荐功能. 更重要的是, 本文进一步考虑了系统在工业场景中的落地可行性, 提出了基于多阶段流水线的课程推荐系统设计, 这在学术界与工业界研究中都尚属首创.

## 2 核心推荐引擎

本节将详细介绍核心推荐引擎设计的细节, 如图1所示. 首先, 将多种隐式交互行为构建为统一化的异构图, 作为后续表征计算和推荐预测的基础框架; 之后, 在各个行为子图之上, 分别进行用户向量的近邻卷积与学习, 在知识空间内实现用户与课程的表征学习; 最后, 基于得到的用户和课程表征向量, 实现了知识指导下的课程推荐预测结果.

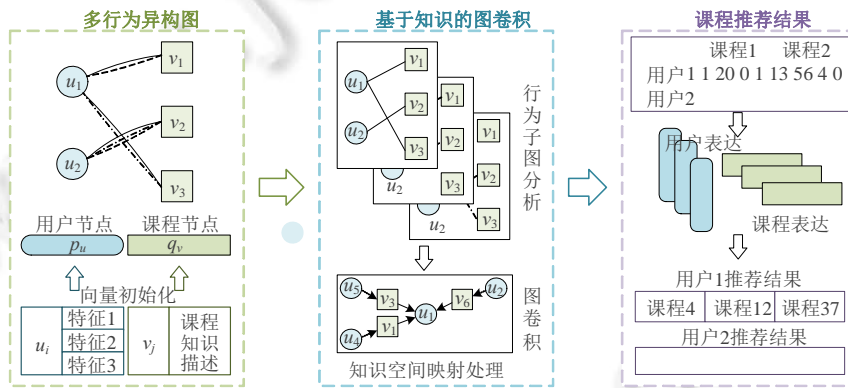


图1 基于隐式多行为与知识的图卷积推荐引擎

### 2.1 基于隐式行为的课程推荐定义

不失一般性, 规定用户和课程集合如下:

$$\text{用户: } U = \{u_i | i = 1, 2, \dots, n_U\} \tag{1}$$

$$\text{课程: } V = \{v_j | j = 1, 2, \dots, n_V\} \tag{2}$$

其中,  $n_U$  是用户总数,  $n_V$  是课程总数.

其次, 规定隐式交互行为的集合为  $H$ :

$$H = \{h_k | k = 1, 2, \dots, n_H\} \tag{3}$$

其中,  $n_H$  是隐式交互行为的类别总数.

最后, 规定交互数据立方体为  $F$ :

$$F = \{f^{h_k} | k = 1, 2, \dots, n_H\} \tag{4}$$

这里,  $f^{h_k}$  是单个隐式行为  $h_k$  对应的“用户-课程”交互矩阵, 矩阵中的每个元素代表对应的用户和课程之间的特定行为交互情况, 其值域为 $\{0,1\}$ :

$$f_{u_i v_j}^{h_k} = \begin{cases} 1, & \text{用户 } i \text{ 和课程 } j \text{ 存在交互 } h_k \\ 0, & \text{用户 } i \text{ 和课程 } j \text{ 没有交互 } h_k \end{cases} \quad (5)$$

值得注意的是: 虽然隐式交互行为集合  $H$  表达为一组元素的序列, 但它是无序序列. 换言之, 行为  $h_{k-1}$  并不表示它发生在  $h_k$  之前. 此外, 不同隐式交互矩阵中的元素值也没有强弱之分, 只表示该行为是否发生.

综上所述, 核心推荐引擎的输入输出为:

- 输入: 在线教育平台上, 用户和课程之间存在  $n_H$  种隐式交互行为, 它们对应的交互矩阵所组成的交互数据立方  $F = \{f^{h_k} | k = 1, 2, \dots, n_H\}$ ;
- 输出: 基于不同隐式交互行为下, 用户  $u_i$  和课程  $v_j$  发生交互的概率, 预测用户  $u_i$  是否会选择学习课程  $v_j$ .

## 2.2 隐式交互行为建模

由于隐式交互数据在工业场景中的普遍性, 如何有效地对其建模, 是推荐系统研究关注的重点之一. 传统的方法通过离散化等转换, 将隐式交互数据建模为“用户-项目”交互矩阵, 进行基于矩阵分解<sup>[30]</sup>或者神经网络<sup>[32]</sup>的计算. 最近, 基于图神经网络的推荐方法开始涌现<sup>[17]</sup>, 相关实验结果表明: 比起建模为矩阵, 将交互建模为图能够避免更多信息损失, 实现更好的推荐性能.

### 2.2.1 统一化异构图

为实现对多种隐式交互数据的全面挖掘, 本文构建了统一化的异构图模型. 具体地, 用户与课程间的交互数据表示为无向图  $G=(W,E)$ :  $W$  为图上的节点集合, 包括用户节点  $u \in U$  以及课程节点  $v \in V$ ;  $E$  则为图上的边集合, 源自用户与课程间的多种隐式交互行为:

$$E = \{e_{u_i v_j}^{h_k} | k = 1, 2, \dots, n_H, i = 1, 2, \dots, n_U, j = 1, 2, \dots, n_V\} \quad (6)$$

这里,  $e_{u_i v_j}^{h_k}$  表示用户  $u_i$  和课程  $v_j$  节点之间对应隐式行为  $h_k$  的连边,  $n_H$  是行为总数,  $n_U$  是用户总数,  $n_V$  是课程总数. 当用户  $u_i$  和课程  $v_j$  之间存在行为  $h_k$  的记录时,  $e_{u_i v_j}^{h_k} = 1$ ; 否则,  $e_{u_i v_j}^{h_k} = 0$ . 这里使用不同类型的边来表示不同的交互行为, 可以实现用户与课程间交互信息最大程度的保留, 确保模型的抽象不会造成信息的明显损失.

进一步地, 根据连边类型, 从交互总图  $G$  中提取出各个交互行为对应子图:

$$G = \{G_{h_k} | k = 1, 2, \dots, n_H\} \quad (7)$$

其中,  $G_{h_k}$  为第  $k$  种行为对应子图,  $n_H$  为隐式交互行为类别总数. 在  $G_{h_k}$  中, 边集合  $E_{h_k}$  只包含特定交互行为  $h_k$  对应的边, 节点集合则是这些边对应的用户和课程节点. 如此, 基于  $G$  可以得到  $n_H$  个单一交互行为子图, 它们将作为后续图卷积计算的基础.

### 2.2.2 节点向量初始化

与已有的图模型类似<sup>[35,40,42]</sup>, 首先要对图  $G$  中的用户和向量节点进行初始化. 具体地, 用户与课程节点的向量定义为

$$p_{u_i} \in R^{U_d}, q_{v_j} \in R^{V_d} \quad (8)$$

这里,  $R^{U_d}$  和  $R^{V_d}$  分别为用户与课程表征向量所在的多维隐式空间维度. 关于节点初始化, 许多研究倾向使用用户/课程 ID 转换而来的独热(one-hot)向量<sup>[14]</sup>, 本文则采用基于节点特征信息的初始化, 以增加节点包含的语义信息, 提升后续向量计算过程的可解释性.

特别地, 本文以知识信息实现了课程节点的初始化, 构建出课程知识隐空间. 知识一直是推荐系统常见的辅助信息<sup>[43]</sup>, 无论是基于标签文本<sup>[18]</sup>, 还是基于知识图谱<sup>[44]</sup>, 许多研究都尝试把知识信息融入推荐系统的表征学习, 并获得了很好的性能提升. 本文对知识类别文本进行了编码, 作为课程节点初始化输入. 后续计算都会在知识空间中开展, 以确保知识信息对课程推荐的主导作用.

### 2.3 知识空间中的多行为图卷积算法

如第 2.2 节所述,我们将“用户-项目”间的隐式交互数据建模为异构图,在此基础上设计了一种创新的图卷积算法,令用户与课程节点蕴含的信息沿着连边传播,进而计算用户与项目的表征向量,实现更精准的推荐预测.如图 2 所示,本算法包括 3 个主要步骤.

- 用户表征向量的学习. 首先,在各个交互行为子图中,通过图卷积运算将用户节点向量映射至课程知识空间;其次,对各个交互图得到的用户表征向量进行聚合统一;最终,从多交互行为记录中挖掘出带有丰富知识信息的用户向量;
- 课程表征向量的增强. 课程节点向量本身已经处于知识空间中,为确保其表征学习的全面性,会通过等价图卷积运算对邻居用户节点的特征信息进行聚合,得到拥有辅助信息增强的课程表征向量;
- 课程推荐结果的预测. 前两部分分别得到用户与课程的最终表征向量后,模型就可以计算“用户-课程”的匹配度得分,据此得到最终的推荐结果.

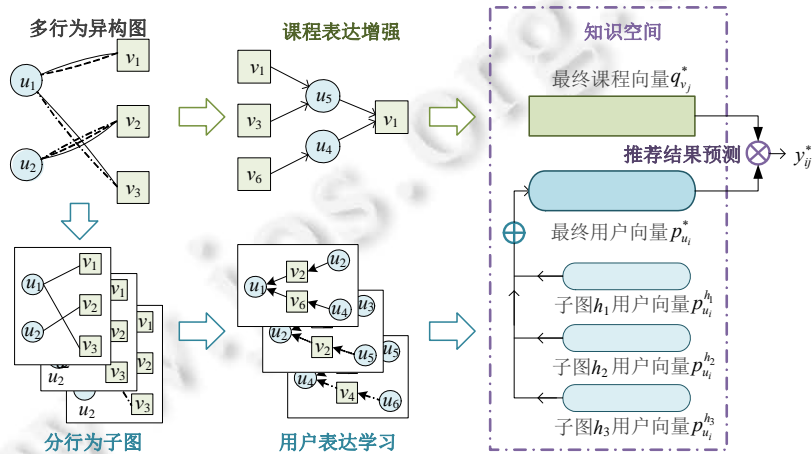


图 2 知识空间中的多行为图卷积推荐算法

#### 2.3.1 用户表征向量的学习

首先,求出各行为子图中的用户节点表征向量.具体地,将多行为异构图拆分为分行为子图,在每个子图中对用户节点执行图卷积运算:

$$p_{u_i}^{h_k} = w_{u_i}^{h_k} \cdot (\text{aggregate}(\tilde{q}_{v_j}^{h_k} | v_j \in V_{Neighbor}^{h_k}(u_i)) + \tilde{p}_{u_i}) \tag{9}$$

这里,  $p_{u_i}^{h_k}$  是用户  $u_i$  对应的节点向量,  $V_{Neighbor}^{h_k}(u_i)$  是行为  $h_k$  下用户  $u_i$  交互过的课程集合,  $\tilde{q}_{v_j}^{h_k}$  为课程节点基于知识特征的初始化向量,  $\text{aggregate}(\cdot)$  是用户节点对相邻课程节点进行卷积运算的映射操作(这里使用了逐维度相加求平均),  $w_{u_i}^{h_k}$  为卷积聚合后的线性映射操作,  $\tilde{p}_{u_i}$  为用户  $u_i$  基于特征的初始化向量.通过在行为子图中基于课程表征向量进行卷积运算,用户节点将被映射至课程知识空间中,并获得对应的用户表征向量.实验发现,基于二阶以上邻居节点的用户卷积计算将极大地提升时间复杂度,而推荐精度提升甚微,故本文将图卷积计算限定在一阶邻居节点.

其次,计算各个行为对应的计算权重.对于从各个行为子图中得到的用户表征向量,提出了一种多行为权重聚合的方法,将行为语义及数据稀疏度纳入多行为用户表征聚合过程.直观而言,不同的交互行为对课程推荐结果的影响程度有所不同,这种差异既源于行为自身的语义信息,也源于行为数据在所有交互数据中的比重.因此,行为权重  $\alpha_{h_k}$  的计算公式如下:

$$\alpha_{h_k} = \frac{w_k \cdot n_k}{\sum_{l=1}^{n_H} w_l \cdot n_l} \quad (10)$$

其中,  $w_k$  是行为语义权重参数,  $n_k$  是行为  $h_k$  在集合  $H$  中的交互次数, 它们分别实现了对隐式行为的语义信息捕捉以及交互稀疏度捕捉. 这里,  $\alpha_{h_k}$  越大, 表明该行为对用户最终的学习决策贡献越大.

最后, 基于行为权重对各子图的用户表征向量进行聚合. 在基于各行为子图得到用户表征向量, 并计算出各个行为的推荐贡献权重后, 本文提出一种编码变换机制, 对用户的多行为表征向量进行聚合, 得到知识空间中的最终用户表征向量  $p_{u_i}^*$ , 计算如公式(11)所示:

$$p_{u_i}^* = w^{U^*} \cdot \left( \sum_{k=1}^{n_H} \alpha_{h_k} \cdot p_{u_i}^{h_k} \right) \quad (11)$$

其中,  $\alpha_{h_k}$  是行为  $h_k$  对应的计算权重,  $w^{U^*}$  是线性变换参数,  $p_{u_i}^{h_k}$  是各行为子图中用户  $u_i$  的表征向量,  $n_H$  是隐式交互行为的类别总数.

### 2.3.2 课程表征向量的增强

课程表征向量已位于知识空间中, 只需要进行改进增强. 与用户不同, 课程拥有相对稳定的知识表征, 不需要考虑融合不同隐式行为的语义信息. 因此对于课程节点的卷积, 不区分行为子图, 直接将各个隐式行为视作相同的一般性交互, 在总图  $G$  中进行等价图卷积, 将邻居用户的特征融入已有的知识向量, 实现对课程表征的增强. 具体卷积计算过程如公式(12)所示:

$$q_{v_j} = \tilde{q}_{v_j} + w_{v_j} \cdot \text{aggregate}(\tilde{p}_{u_i} | u_i \in U_{\text{Neighbor}}(v_j)) \quad (12)$$

这里,  $q_{v_j}$  是课程  $v_j$  对应的节点向量,  $\tilde{q}_{v_j}$  为课程  $v_j$  基于所含知识的初始化向量,  $U_{\text{Neighbor}}(v_j)$  是课程  $v_j$  有过交互的用户集合,  $\tilde{p}_{u_i}$  为用户节点基于用户特征的初始化向量,  $\text{aggregate}(\cdot)$  是课程节点对相邻用户节点的卷积运算(逐维度相加求平均),  $w_{v_j}$  为卷积聚合后的线性映射操作. 通过对用户特征信息的卷积与拼接, 课程节点在知识空间中已有的表征向量将得到增强. 与用户表征向量计算相同, 这里也把图卷积计算限定在一阶邻居节点.

### 2.3.3 课程推荐结果的预测

在知识空间中获得最终用户表征向量和课程表征向量后, 采用内积计算用户  $u_i$  与课程  $v_j$  的匹配度  $y_{ij}^*$ , 计算过程如公式(13)所示:

$$y_{ij}^* = \langle p_{u_i}^*, q_{v_j}^* \rangle \quad (13)$$

其中,  $p_{u_i}^*$  是用户  $u_i$  的最终表征向量,  $q_{v_j}^*$  是课程  $v_j$  的最终表征向量.

## 2.4 模型训练

在模型训练阶段, 采用贝叶斯个性化排序损失函数(Bayesian personalized ranking)进行模型优化, 以学习模型中的各种参数. BPR 是推荐系统研究中常用的一种模型优化方法, 不同于其他基于用户评分的方法, BPR 能够基于隐式反馈指导模型优化, 相关函数定义如公式(14)所示:

$$Loss = \sum_{(u,i,j) \in O} -\ln \sigma(y(u,i) - y(u,j)) + \beta \cdot \|\Theta\|^2 \quad (14)$$

其中,  $O = \{(u,i,j) | (u,i) \in R^+, (u,j) \in R^-\}$  表示目标行为的训练数据集,  $R^+$  辨识用户已有交互的目标行为,  $R^-$  表示用户没有产生交互的目标行为,  $\sigma(\cdot)$  是 sigmoid 函数,  $\Theta$  表示所有的可训练参数,  $\beta$  是 L2 正则化系数.

同时, 为防止模型训练出现过拟合现象, 在模型训练过程中引入信息 dropout、节点 dropout. 其中, 当信息 dropout 指的是向量初始化时, 则以概率  $p_{init}$  随机丢弃用户的一些信息特征; 当节点 dropout 指的是图卷积计算时, 则以概率  $p_{conv}$  随机丢弃部分邻居节点.



### 3 推荐流水线设计

为满足工业场景的课程推荐需求, 本文设计并开发了一套多阶段推荐流水线. 这套流水线通过 5 个主要环节, 将大规模数据过滤、重量级数据处理、轻量级结果输出实现异步分离, 提升了整体运行效率. 如图 3 所示, 流水线具体包括: (1) 基础数据处理; (2) 基于知识分类的快速召回; (3) 基于引擎的离线推荐; (4) 面向时效性的在线推荐; (5) 针对冷启动的融合输出.

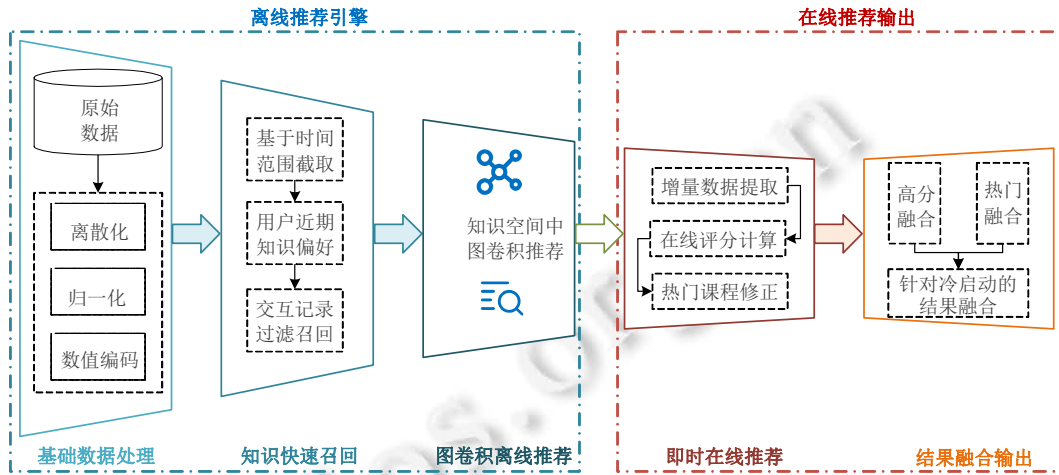


图 3 面向在线教育场景的课程推荐流水线

#### 3.1 基础数据预处理

针对原始输入数据中的非结构化隐式交互记录, 通过多种措施对其实行规范化处理.

数值型交互记录的处理包括离散数值和连续数值的处理.

- 离散化数值如评分  $R$ , 一般是三分制或五分制, 其定义域明确, 直接保留即可; 至于用户对特定课程的学习时长  $T_i$ , 需要进行基于阈值的映射处理, 使其反映用户对课程的学习偏好度:

$$T_i = \begin{cases} 1, & T_i \geq T_{middle} \\ 0, & T_i < T_{middle} \end{cases}, T_{middle} \text{ 为用户学习时长中位数} \quad (15)$$

- 连续型的数值, 如用户学习的积分  $P_i$ , 则通过数据归一化处理, 将其映射至  $[0,1]$  区间, 即:

$$P_i = \frac{P_i}{P_{max}}, P_{max} \text{ 为全体用户中积分数的最大值} \quad (16)$$

对于非数值类交互记录, 需要进行数值化的转换. 如评论、收藏等“用户-课程”交互行为, 可以直接将行为的发生记为 1, 未发生记为 0; 对于课程知识点等复杂的文本信息, 则需要进行更精细的编码处理, 即统计到全部的知识点文字数据, 将其转换为后续神经网络处理能够输入的向量类型数据. 这种文字向量化的处理方式选择很多, 有基于新兴 BERT 模型的转换编码, 也有基于经典 word2vec 方法的转换编码, 甚至独热编码也可以.

通过以上处理, 原始的输入数据将能够转换为后续神经网络步骤可接收的数据格式, 既消除了原始数据中的噪声数据, 也保留了有助于用户画像建模的高价值信息.

#### 3.2 基于知识的快速召回

针对预处理后的庞大数据, 设计了基于知识分类的快速召回机制, 实现了有针对性的过滤. 首先设定了基于时间阈值的交互记录截断机制, 获取最近一段时间范围内的隐式交互数据; 之后, 对近期交互记录包含的课程数据进行抽取, 得到用户近期学习过的知识信息, 提取学习画像; 最后, 基于近期学习画像, 再对隐式交互记录进行反向过滤, 得到小规模交互记录数据子集, 作为后续核心推荐引擎的输入.

召回环节作为推荐系统在工业界应用时是必不可少的环节, 有的企业会选择基于深度学习的复杂机制, 如基于图卷积神经网络的召回<sup>[18]</sup>、基于双塔神经网络的召回<sup>[16]</sup>等. 这些深度召回机制依赖于充足的计算资源, 实现了较为精细的数据过滤; 但是这种性能的提升对算力的依赖过强, 不具有一般性. 所以在本流水线设计中, 召回环节使用了简化的策略, 而复杂的深度推荐算法留在后续的离线推荐引擎中.

### 3.3 基于核心引擎的离线推荐

在召回得到的交互数据的基础上, 就可以将其输入之前的核心推荐引擎, 进行基于深度图卷积的预测计算. 这部分工作相比流水线其他环节, 需要进行参数量庞大的迭代计算, 不宜放在线上即时运行, 故对其进行了异步分离, 将其置于平台主要服务进程以外, 周期性地离线运行. 当系统前端需要响应用户的课程推荐请求时, 直接读取引擎产生的输出数据, 以确保用户体验的友好.

### 3.4 在线快速推荐

针对核心引擎的异步性, 提出了在线推荐机制, 以弥补离线推荐结果在时效性方面的差距. 为确保最终推荐结果更加真实地反映用户的实时学习画像, 以离线推荐结果为主体, 基于新增交互记录进行增量化快速协同过滤, 增强了结果的时效性. 同时, 本环节也会提升推荐结果的新颖度.

具体地, 本环节分为 4 个步骤: (1) 在系统中提取增量的“用户-课程”交互记录数据, 即自上次离线推荐引擎运行开始, 到当前时刻的这段时间内, 用户新产生的交互数据; (2) 基于增量数据, 借助 Spark 等流式处理工具实现快速协同过滤, 得到“用户-课程”推荐对间的增量预测值  $\alpha$ ; (3) 设定学习时长阈值, 对用户交互过的课程进行过滤, 为对应课程知识赋予贡献值  $\beta$ ; 最后, 对离线推荐结果进行增强, 计算公式如下:

$$R_{ij} = y_{ij}^* + \alpha_{ij} + \beta_{ij} \quad (17)$$

其中,  $R_{ij}$  为增强后的“用户  $i$ -课程  $j$ ”推荐预测值,  $y_{ij}^*$  为核心推荐引擎得到的推荐值,  $\alpha_{ij}$  为“用户  $i$ -课程  $j$ ”对应的增量预测值,  $\beta_{ij}$  为对应的知识贡献值.

此外, 还会对预测分数进行基于课程点击数的热门度惩罚, 降低热门课程对最终推荐结果的影响, 提升推荐结果的新颖度. 具体计算如下:

$$R'_{ij} = R_{ij} - \frac{hit_{ij}}{2hit_{max}} \quad (18)$$

其中,  $R'_{ij}$  为经过热门惩罚修正的推荐值,  $R_{ij}$  为上一步增量化处理后的推荐值,  $hit_{ij}$  为用户  $i$  对课程  $j$  的点击次数,  $hit_{max}$  为所有点击交互记录的最大值. 经过热门惩罚修正, 最热门的课程会得到 0.5 的惩罚值, 而非热门课程基本不受影响, 推荐结果的新颖性也由此得到保障.

### 3.5 输出结果融合

针对新用户的冷启动问题, 在流水线最后增加了输入结果的融合处理操作. 冷启动问题是推荐系统面临的主要挑战之一, 即对于新注册的用户, 平台缺少交互记录, 无法从中获取用户画像, 从而提供准确的预测结果. 对此, 本文提出了推荐结果融合策略, 向冷启动的新用户提供非个性化推荐, 作为其个性化推荐补充. 关于非个性化推荐结果与个性化推荐结果之间比例的平衡, 由冷启动参数  $cold_i$  予以调节:

$$cold_i = \text{relu} \left( \frac{n_{records}^{thresh} - n_{records}^i}{n_{records}^{thresh}} \right) \quad (19)$$

其中,  $n_{records}^i$  是用户  $i$  已有的课程交互记录数,  $n_{records}^{thresh}$  是面向新用户的冷启动阈值,  $\text{relu}(\cdot)$  为线性整流函数. 当用户的交互记录数小于冷启动阈值  $n_{records}^{thresh}$  时, 其对应的  $n_{records}^i$  就是位于 (0,1) 的小数, 这说明, 该用户正面临冷启动问题; 反之, 当用户的交互记录数充足时, 其对应的  $cold_i$  就是 0, 说明其已摆脱冷启动困境. 在冷启动参数  $cold_i$  的基础上, 对应的非个性化推荐结果增强如下:

$$C_{Pred} = C_{hit} + C_{rate} + C_{rec} \quad (20)$$

其中,  $C_{Pred}$  为最终推荐课程集合;  $C_{hit}$  为高点击课程集合, 占比  $a/2$ ;  $C_{rate}$  为高评分课程集合, 占比  $a/2$ ;  $C_{rec}$  为第

3.4 节中提及的在线快速推荐得到的推荐结果集合, 占比 $(1-a)$ .  $C_{hit}$ 、 $C_{rate}$ 、 $C_{rec}$  融合时会进行课程去重, 如果未达到最终推荐列表长度, 则由个性化推荐结果进行基于推荐值降序的递补.

这里, 当用户是新注册而没有任何交互记录时, 平台提供的推荐课程完全为非个性化推荐, 包括一半的高点击课程和一半的高评分课程; 当用户有了一定交互记录时, 平台会逐渐增加个性化推荐结果的比例; 当用户交互记录数高于冷启动阈值后, 平台会停止非个性化推荐增强, 完全依赖个性化推荐. 如此, 通过输出结果融合, 有针对性地解决了新用户的冷启动问题, 且计算成本不高, 满足工业界在线教育场景的落地需求.

## 4 实验与分析

本节介绍对于图学习智慧课程推荐系统的实验设计与结果分析, 具体目的分为两方面.

- (1) 基于真实课程学习数据集, 对比其他前沿推荐算法, 验证核心推荐引擎的准确率;
- (2) 基于工业场景的用户案例, 分析推荐流水线可用性, 特别是在线推荐的响应、知识关联的体现、冷启动问题的解决.

### 4.1 实验环境与设计

#### 4.1.1 课程学习数据集

本实验所用在线课程学习数据集来自上海复深蓝在线学习平台. 目前尚未有广泛使用与承认的课程学习公开数据集, 故我们与上海某金融科技公司合作, 使用了其自有平台“复深蓝”提供的学习数据. 该公司主要业务之一是为数字化企业培训平台服务, 向上海数十家不同规模的金融保险公司提供职业课程在线培训, 培训形式包括在线视频学习、线下课程组织、日常作业检查、结业证书考试等, 其中, 在线视频课程类别丰富, 包括金融基础、企业党建、金融法律、公司业务等. 我们选取了复深蓝平台在 2020 年 4 月–2020 年 10 月期间的在线视频学习数据作为训练输入, 涉及用户 1 000 多位、课程 300 多门、多种“用户-课程”隐式交互.

复深蓝数据集总计有 17 224 条“用户-课程”学习数据, 每条数据最多包含 4 种交互记录(收藏、评论、学习时长、评分), 相关统计信息见表 1.

表 1 复深蓝数据集概况

数据集	用户数目	课程数目	收藏记录数	评论记录数	时长记录数	评分记录数	课程类别数
复深蓝数据集	1 303	343	17 224	189	16 877	972	24

此外, 培训课程类别共有 24 类, 部分类别示例见表 2.

表 2 课程类别概况

序号	类别 ID	类别名称
1	15030	系列培训
2	15365	法制讲堂
3	15607	保险课程
...	...	...

在工业场景中, 数据稀疏性十分普遍, 为了验证所提出的推荐方法面临稀疏性的表现, 这里进行了稀疏子集的提取. 具体地, 在当前 1W 级别数据的基础上, 确保用户数不变, 对各个交互记录进行了随机采样, 得到规模更小的 5k 级别数据, 作为稀疏数据子集, 以此验证各推荐方法面临工业场景稀疏性问题时的性能.

#### 4.1.2 超参数设置

本文的核心推荐引擎基于 DGL 实现. DGL 是亚马逊 AWS 团队于 2018 年正式发布的深度学习框架, 支持传统张量运算到图运算的自由转换, 并且能够自定义消息传递过程, 为图神经网络各项计算提供了良好支撑.

图神经网络设置方面, 将图卷积计算的层数设置为 1, 隐藏层的维度设为 16. 为防止过拟合, 在卷积计算中增加了基于  $P=0.5$  的 *dropout* 层. 同时, 为提升图计算效率<sup>[14]</sup>, 将卷积计算的激活函数从 *reLu* 更换为 *Linear*. 模型训练设置方面, 使用 Adam 作为优化器进行小批量数据训练, 每批数据规模为 1 000 条, 训练轮次设为 50.

### 4.1.3 核心引擎对比算法

关于核心推荐引擎的对比算法, 选取了 3 个具有代表性的神经网络推荐算法, 分别是 MLP 神经网络协同过滤算法、LightGCN 轻量级图卷积神经网络算法、MultiVAE 变分编码协同过滤算法。

- MLP: MLP<sup>[32]</sup>应用十分广泛, 是经典的深度学习推荐方法. 除了基本输入输出层, MLP 在中间设定了多个隐藏层, 用于学习用户与项目表征, 实现协同过滤;
- LGCN: LightGCN<sup>[14]</sup>通过在用户-项目交互图上线性传播用户和项目消息, 基于高阶图卷积与线性变换来学习用户和项目表征, 最终得到推荐计算结果;
- MVAE<sup>[45]</sup>将变分自编码器(VAE)扩展到协同过滤, 引入了具有多项式似然(multinomial likelihood)的生成模型, 从而基于贝叶斯推断实现参数估计, 完成推荐预测。

### 4.1.4 算法评估指标

为了评估推荐模型的性能, 使用了两个推荐系统常见的指标, 分别是 Precision 和 NDCG。

- Precision@K 计算在排名前 K 的推荐结果中, 用户实际交互过的项目占比;
- NDCG@K 计算排名前 K 的推荐结果列表, 与用户实际交互过的项目列表差距。

实验运行与指标计算所用设备为个人电脑, CPU 为 Intel i7-10875H, 8 核心, 2.3 GHz 主频; 内存规格为 DDR4, 16 GB 容量。

## 4.2 离线引擎实验

### 4.2.1 实验结果

在 5k 与 10k 两个规模的课程学习数据集上, 对比了提出的核心推荐引擎与其他前沿推荐算法, 并监测了 Precision@5、Precision@10、NDCG@5、NDCG@10 这 4 项指标, 具体结果见表 3。

表 3 推荐引擎实验结果

数据规模	Precision@K				NDCG@K			
	5k		10k		5k		10k	
计算指标	Prec@5	Prec@10	Prec@5	Prec@10	NDCG@5	NDCG@10	NDCG@5	NDCG@10
MLP	<b>0.457 7</b>	<b>0.362 2</b>	0.454 9	0.420 4	0.976 7	0.974 5	<b>0.997 7</b>	<b>0.994 6</b>
LGCN	0.078 9	0.074 5	0.193 3	0.170 8	0.888 0	0.870 1	0.935 2	0.929 8
MVAE	0.206 2	0.182 6	0.284 8	0.272 5	0.737 9	0.734 6	0.820 8	0.837 9
<b>Ours</b>	0.283 6	0.269 7	<b>0.653 4</b>	<b>0.656 4</b>	<b>0.986 5</b>	<b>0.984 3</b>	0.995 6	0.968 4

从结果来看, 本文提出的推荐引擎性能十分优异. 在两种数据规模下, 引擎的 4 项指标的结果基本都能优于其他算法: 5k 级别的 NDCG 指标与 10k 级别的 Precision 指标都是第一; 在其他情况下, 也和第一的算法不相上下。

此外, 我们的推荐引擎面对数据稀疏性的表现也很好. 从指标计算情况来看, 当数据集规模从 10k 下降至 5K 时, 每个算法的性能都会因稀疏性下降. 在 NDCG 指标下, 该推荐引擎下降值最小; 在 Precision 指标下, 虽然 4 项算法性能都有大幅下滑, 但该引擎仍然保持了排名前列. 总体来看, 本文所提出的核心推荐引擎在面临数据稀疏性问题时受到的负面影响较小, 能够保持较强的鲁棒性。

### 4.2.2 讨论分析

本文提出的核心推荐引擎相比其他 3 种主流方法在性能上表现比较优异。

- 一方面, 本引擎优势在于对多种隐式交互行为的利用: MLP 与 MVAE 虽然能够将课程知识、用户属性等辅助信息融入到推荐计算中, 但其计算完全基于“用户-课程”单一交互(典型如评分)来实现, 没有充分利用其他隐式交互行为, 导致最终指标结果不如本引擎. 可见, 多种交互信息蕴含的“用户-课程”复杂关联, 有助于提升模型的代表学习性能。
- 另一方面, 本引擎优势在于将知识的指导作用融入了推荐过程: LGCN 同样使用图神经网络挖掘了“用户-课程”交互记录, 但是课程向量初始化仅使用了 ID 独热编码, 缺乏其他辅助信息, 特别是课程知识信息的融入. 从实验结果来看, LGCN 方法的课程推荐效果相比其他方法劣势明显. 可见, 没有

知识等辅助信息的支持,即使是热门的图卷积神经网络方法,也无法完全发挥其作用。

### 4.3 在线案例分析

除了对离线核心推荐引擎进行实验,本文还对开发的多阶段流水线式推荐系统原型进行了案例分析。基于交互稀疏度不同的两位用户交互记录,运行流水线推荐原型得到了推荐值最高的 5 门课程。以下将从请求响应时间、推荐知识关联度、冷启动解决情况这 3 个方面分析流水线原型面临工业场景需求的可用性。

#### 4.3.1 案例 1: 交互丰富用户

选取了一位课程交互记录数丰富的用户,对其展开案例分析。该用户的课程交互概况见表 4。

表 4 交互丰富的用户案例概况

用户 ID	课程	交互记录数	课程类别数
189447792423374	24	103	5

该用户交互过的 5 种课程类别信息以及对应的 24 门课程信息见表 5。

表 5 课程类别交互信息

课程类别名 对应课程数	风险文化宣讲 6	会计营运大讲堂 4	系列培训 4	保险课程: 主讲人重立 9	设备操作培训 1
----------------	-------------	--------------	-----------	------------------	-------------

分析可得,该用户主要关注保险/风险相关课程,这类对应课程数量占据全部已交互课程的 60%以上;会计相关课程占 30%左右,并不是用户关注的重点内容;而设备操作类课程只有一门,且与其他类别课程区别较大,可将其视为噪声数据。

经过本文在线推荐系统原型进行推荐后,5 次请求的平均耗时为 4.447 s,具体耗时情况见表 6。

表 6 交互丰富用户 5 次推荐耗时情况

推荐次数	第 1 次	第 2 次	第 3 次	第 4 次	第 5 次
推荐耗时(s)	4.126	4.437	4.891	4.179	4.602

由于对计算成本高昂的离线深度模型训练进行了异步分离,本在线推荐系统原型十分轻便,更加符合在线教育应用场景的部署需求。若将运行设备更换为工业场景中的高性能服务器,在线推荐耗时将进一步缩短。该用户得到的推荐学习课程前 5 名情况见表 7。

表 7 推荐课程前 5 名情况

课程名 课程类别	保险审计须知 内部审计	客户关系维护 保险业培训师获奖课程	内部风险防范 内部审计	境外资金管理 国家安全	销售培训 2 期 营业网点规范需知
-------------	----------------	----------------------	----------------	----------------	----------------------

这 5 门课程的类别,主要的 3 门课与保险相关(保险审计须知、销售培训 2 期、客户关系维护),其次有 2 门课与会计审计相关(内部风险防范、境外资金管理),而作为数据噪声的设备操作类课程并未明显影响到推荐结果。以上个性化推荐课程与该用户学习画像保持了高度一致,这体现了推荐系统原型中知识的关键指导作用。同时,由于该用户交互丰富,相关记录数超出设定的冷启动阈值,非个性化课程补充机制未被激活。

#### 4.3.2 案例 2: 交互稀疏用户

选取了一位课程交互记录数稀疏的用户,对其展开案例分析。该用户的课程交互概况见表 8。

表 8 交互稀疏的用户案例概况

用户 ID	课程	交互记录数	课程类别数
1277507619430477824	11	34	2

该用户交互过的两种课程类别信息以及对应的课程信息见表 9。

表 9 课程类别交互信息

课程类别名 对应课程数	党建会议精神 5	运营管理 6
----------------	-------------	-----------

由此可见, 该用户主要关注运营管理类课程, 对应课程数量所占比例超过一半; 关于党建会议精神也是学习的另一主题. 但从整体来看, 不论是课程类别数、交互记录数, 还是课程学习数, 该用户的学习数据都比较稀疏, 对其学习画像的反映有限, 在推荐系统中容易遇到冷启动问题.

经过本文在线推荐系统原型进行推荐后, 5 次请求的平均耗时为 4.413 s, 具体耗时情况见表 10.

表 10 交互稀疏用户 5 次推荐耗时情况

推荐次数	第 1 次	第 2 次	第 3 次	第 4 次	第 5 次
推荐耗时(s)	4.223	4.401	4.669	4.582	4.190

交互稀疏用户的在线推荐过程保持了计算的轻便性, 并且由于稀疏用户需要处理的数据更少, 整体耗时相比交互丰富用户更短.

该用户得到的推荐学习课程前 5 名情况见表 11.

表 11 推荐课程前 5 名情况

课程名	民主生活会指南	多部门协作技巧	坏账审计要点	常见金融风险防范	入职须知 20 条
课程类别	党群工作	入职培训	内部审计	风险文化宣讲	职工讲堂

值得注意的是: 这 5 门推荐的课程, 第 1 门对应该用户关注的知识(党建), 后 3 门则是平台高评分/高点击课程, 这是源自输入结果融合环节的非个性化推荐增强. 总体来看, 本原型提供的个性化推荐课程与该用户有限的学习画像保持了基本一致, 且面对历史记录稀疏的用户, 原型还能够提供高价值的补充课程.

### 4.3.3 用例分析总结

首先, 无论是交互丰富用户还是稀疏用户, 本原型都可以有效提供符合其知识画像的个性化推荐课程, 这得益于离线推荐引擎对隐式交互的有效利用以及对知识信息的突出体现.

值得注意的是, 交互丰富用户与稀疏用户的推荐响应指标之间存在不同, 这反映了数据稀疏度对推荐过程的影响以及本原型对其负面影响的缓解.

- 就推荐过程的平均耗时而言, 交互稀疏用户的耗时整体上会比交互丰富用户的耗时更短. 这是因为, 稀疏用户需要处理的数据量相对较小, 计算过程相对简短;
- 就推荐课程的覆盖情况而言, 丰富用户的课程更好地对应了其个性化学习知识要点, 而稀疏用户的结果更多源自非个性化推荐, 这是对其冷启动困境的良好缓解.

最后, 综合两种不同稀疏度用户的课程推荐结果来看, 本文提出的在线推荐系统原型具有如下优势, 能够有效满足工业场景的课程推荐需求.

- 快速响应推荐请求. 得益于“在线+离线”的异步计算机制, 虽然实验环境为单台性能不高的笔记本电脑, 但原型平均响应时间也能保持在 4.4 s 左右;
- 知识指导推荐结果. 本系统在课程知识空间中构建隐式交互行为图, 挖掘用户学习画像, 确保课程推荐的主导因素为课程知识, 而非交互的热门度;
- 缓解交互稀疏难题. 对于交互稀疏、学习画像缺失的用户, 本系统能够有效缓解其冷启动问题, 以高质量的非个性化课程补充个性化推荐的不足.

## 5 总结与展望

为推动推荐算法与在线教育场景相融合, 实现个性化的智慧课程学习, 本文设计了一套面向工业场景的课程推荐系统. 核心推荐引擎方面, 基于图卷积神经网络推荐算法, 对“用户-课程”隐式交互行为数据建模, 将课程知识融入深度学习过程, 全面挖掘“用户-课程-知识”间的关联. 在此离线引擎的基础上, 进一步设计了高效的多阶段推荐流水线, 不仅能够快速响应课程推荐请求, 更能有针对性地缓解冷启动问题——推荐算法落地最大的障碍之一, 提升了用户的使用体验. 最后, 基于真实课程学习平台数据集, 以对比实验表明了离线推荐引擎的先进性, 同时以典型用例分析展示了在线推荐系统的可用性.

后续,我们将根据工业界推荐流水线的通用设计原则,对本推荐系统进行改造.针对离线推荐引擎,一方面会在数据预处理环节前置数据增强模块,实现对稀疏数据的针对性增强;另一方面,会在图卷积推荐环节增加基于概率生成的负采样模块,实现深度学习训练数据的优化.针对在线推荐系统,会增加面向学习路径的序列式课程推荐,实现时间维度上更长期的课程推荐,这也更符合课程知识学习的一般性规律.

## References:

- [1] Liu B, Xue NN, Guo HF, Tang RM, Stefanos Z, He XQ, Li ZG. AutoGroup: Automatic feature grouping for modelling explicit high-order feature interactions in CTR prediction. In: Proc. of the 43rd ACM Conf. on Research and Development in Information Retrieval. New York: ACM, 2020. 199–208.
- [2] Shang YM, Cao YN, Liu YB. Combining content-aware and heterogeneous-aware for event recommendation. Ruan Jian Xue Bao/Journal of Software, 2020, 31(4): 1212–1224 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5544.htm> [doi: 10.13328/j.cnki.jos.005544]
- [3] Xu HL, Wu X, Li XD, Yan BP. Comparison study of Internet recommendation system. Ruan Jian Xue Bao/Journal of Software, 2009, 20(2): 350–362 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/3388.htm> [doi: 10.3724/SP.J.1001.2009.03388]
- [4] Tang CL, Liao JX, Wang HC, Sung CY, Lin WC. Conceptguide: Supporting online video learning with concept map-based recommendation of learning path. In: Proc. of the Web Conf. Ljubljana: ACM, 2021. 12.
- [5] Wang C, Zhu HS, Zhu C, Zhang X, Chen E, Xiong H. Personalized employee training course recommendation with career development awareness. In: Proc. of the Web Conf. ACM, 2020. 12.
- [6] Asmaa E, George K. Domain-aware grade prediction and top- $n$  course recommendation. In: Proc. of the 10th ACM Conf. on Recommender Systems. New York: ACM, 2016. 183–190.
- [7] Shen M, Lai TP, Wang SM, Peng YM, Gao ZT. Design and implementation of the course recommendation engine in Peking University. CAAI Trans. on Intelligent Systems, 2015, 10(3): 369–375 (in Chinese with English abstract).
- [8] Liu X, He JR, Sam D, Liz O. Convolution-consistent collective matrix completion. In: Proc. of the 28th ACM Conf. on Information and Knowledge Management. New York: ACM, 2019. 2209–2212.
- [9] Huang LW, Jiang BT, Lv SY, Liu YB, Li DY. Survey on deep learning based recommender system. Chinese Journal of Computers, 2018, 41(7): 1619–1647 (in Chinese with English abstract).
- [10] Huang YY, Kuo TY, Chen HH. Selecting representative thumbnail image and video clip from a video via bullet screen. In: Proc. of the Web Conf. New York: ACM, 2020. 48–49.
- [11] Xu C, Li Q, Ge JF, Gao JY, Yang XY, Pei CH, Sun F, Wu J, Sun HX, Ou WW. Privileged features distillation at taobao recommendations. In: Proc. of the 26th ACM Conf. on Knowledge Discovery & Data Mining. New York: ACM, 2019. 2590–2598.
- [12] Li XJ, Liu H, Shi HX, Zhu LQ, Zhang YH. Deep learning based course recommendation model. Journal of Zhejiang University (Engineering Science), 2019, 53(11): 2139–2145, 2162 (in Chinese with English abstract).
- [13] Ge Y, Chen SC. Graph convolutional network for recommender systems. Ruan Jian Xue Bao/Journal of Software, 2020, 31(4): 1101–1112 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5928.htm> [doi: 10.13328/j.cnki.jos.005928]
- [14] He XN, Deng K, Wang X, Li Y, Zhang YD, Wang M. LightGCN: Simplifying and powering graph convolution network for recommendation. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. New York: ACM, 2020. 639–648.
- [15] Paul C, Jay A, Emre S. Deep neural networks for YouTube recommendations. In: Proc. of the 10th ACM Conf. on Recommender Systems. New York: ACM, 2016. 191–198.
- [16] Huang JT, Ashish S, Sun SY, Xia Li, David Z, Philip P, Janani P, Giuseppe O, Yang LJ. Embedding-based retrieval in Facebook search. In: Proc. of the 26th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining. New York: ACM, 2020. 2553–2561.
- [17] Rex Y, He RN, Chen KF, Pong E, William L, Jure L. Graph convolutional neural networks for Web-scale recommender systems. In: Proc. of the 24th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining. New York: ACM, 2018. 974–983.
- [18] Liu Q, Xie RB, Chen L, Liu SK, Tu K, Cui P, Zhang B, Lin LY. Graph neural network for tag ranking in tag-enhanced video recommendation. In: Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management. New York: ACM, 2020. 2613–2620.
- [19] Yehuda K, Robert B, Chris V. Matrix factorization techniques for recommender systems. Computer, 2009, 8(42).

- [20] Liu HF, Jing LP, Yu J. Survey of matrix factorization based recommendation methods by integrating social information. *Ruan Jian Xue Bao/Journal of Software*, 2018, 29(2): 340–362 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5391.htm> [doi: 10.13328/j.cnki.jos.005391]
- [21] Yehuda K. Factorization meets the neighborhood: A multifaceted collaborative filtering model. In: *Proc. of the 43rd ACM Conf. on Knowledge Discovery & Data Mining*. New York: ACM, 2008. 426–434.
- [22] Chen JY, Zhang HW, He XN, Nie LQ, Liu W, Tat-Seng C. Attentive collaborative filtering: Multimedia recommendation with item- and component-level attention. In: *Proc. of the 40th ACM Conf. on Research and Development in Information Retrieval*. New York: ACM, 2017. 335–344.
- [23] Marco G, Augusto P. ItemRank: A random-walk based scoring algorithm for recommender engines. In: *Proc. of the 20th AAAI Conf. on Artificial Intelligence*. Hyderabad: AAAI, 2007. 2766–2771.
- [24] Shi C, Hu BB, Zhao WX, Yu PS. Heterogeneous information network embedding for recommendation. *IEEE Trans. on Knowledge and Data Engineering*, 2019, 31(2): 357–370.
- [25] Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: *Proc. of the 31st NIPS Conf. on Neural Information Processing Systems*. NIPS, 2017. 1025–1035.
- [26] Thomas NK, Max W. Semi-supervised classification with graph convolutional networks. In: *Proc. of the 5th ICLR Conf. on Learning Representations*. Toulon: ICLR, 2017. 14.
- [27] Wang X, He XN, Wang M, Feng FL, Tat-Seng C. Neural graph collaborative filtering. In: *Proc. of the 42nd ACM Conf. on Research and Development in Information Retrieval*. New York: ACM, 2019. 165–174.
- [28] Rianne VDB, Thomas NK, Max W. Graph convolutional matrix completion. In: *Proc. of the 24th ACM Conf. on Knowledge Discovery & Data Mining*. London: ACM, 2018. 9.
- [29] David G, David N, Brian M, Douglas T. Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 1992. 61–70. [doi: 10.1145/138859.138867]
- [30] Liu K, Li XY, Zhu ZH, Lodewijk B, Wang H. Factor-bounded nonnegative matrix factorization. *ACM Trans. on Knowledge Discovery from Data*, 2021. 18.
- [31] Lin X, Zhang WP, Zhang M, Zhu WW, Pei J, Zhao PL, Huang JZ. Online compact convexified factorization machine. In: *Proc. of the 2018 World Wide Web Conf.* ACM, 2018. 1633–1642.
- [32] He XN, Liao LZ, Zhang HW, Nie LQ, Hu X, Chua TS. Neural collaborative filtering. In: *Proc. of the 26th Int'l Conf. on World Wide Web*. ACM, 2017. 173–182.
- [33] Feng Y, Zhang B, Qiang BH, Zhang YY, Shang JX. MN-HDRM: A novel hybrid dynamic recommendation model based on long-short-term interests multiple neural networks. *Chinese Journal of Computers*, 2019, 42(1): 16–28 (in Chinese with English abstract).
- [34] Xu CF, Zhao PP, Liu YC, Xu JJ, Victor S, Cui ZM, Zhou XF, Xiong H. Recurrent convolutional neural network for sequential recommendation. In: *Proc. of the World Wide Web Conf.* New York: ACM, 2019. 3398–3404.
- [35] Gong JB, Wang S, Wang JL, Feng WZ, Peng H, Tang J, Philip S. Attentional graph convolutional networks for knowledge concept recommendation in MOOCs in a heterogeneous view. In: *Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval*. ACM, 2020. 10.
- [36] He XR, Pan JF, Jin O, Xu TB, Liu B, Xu T, Shi YX, Antoine A, Ralf H, Stuart B, Joaquin Q. Practical lessons from predicting clicks on ADS at Facebook. In: *Proc. of the 8th Int'l Workshop on Data Mining for Online Advertising*. New York: ACM, 2014. 1–9.
- [37] Zhou GR, Zhu XQ, Song CR, Fan Y, Zhu H, Ma X, Yan YH, Jin JQ, Li H, Gai K. Deep interest network for click-through rate prediction. In: *Proc. of the 24th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining*. New York: ACM, 2018. 1059–1068.
- [38] Dai J. Bridge the gap: Industrial data pipeline oriented recommendation enhancement. In: *Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval*. New York: ACM, 2021. 1.
- [39] Fan M, Guo JC, Zhu S, *et al.* MOBIUS: Towards the next generation of query-ad matching in Baidu's sponsored search. In: *Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery*. Anchorage: ACM, 2019. 2509–2517.
- [40] Jin BW, Gao C, He XN, Jin DP, Li Y. Multibehavior recommendation with graph convolutional networks. In: *Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval*. New York: ACM, 2020. 10.
- [41] Ajit P, Geoffrey J. Relational learning via collective matrix factorization. In: *Proc. of the 14th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining*. New York: ACM, 2008. 650–658.



- [42] Zheng Y, Gao C, He X, Li Y, Jin D. Price-aware recommendation with graph convolutional networks. In: Proc. of the 36th IEEE Int'l Conf. on Data Engineering. IEEE, 2020. 133–144.
- [43] Shi Y, Martha L, Alan H. Mining contextual movie similarity with matrix factorization for context-aware recommendation. ACM Trans. on Intelligent Systems and Technology, 2013, 19.
- [44] Wang HW, Zhao M, Xie X, Li WJ, Guo MY. Knowledge graph convolutional networks for recommender systems. In: Proc. of the World Wide Web Conf. New York: ACM, 2019. 3307–3313.
- [45] Liang D, Rahul G, Matthew D, Tony J. Variational autoencoders for collaborative filtering. In: Proc. of the 2018 World Wide Web Conf. ACM, 2019. 689–698.

#### 附中文参考文献:


- [2] 尚燕敏, 曹亚男, 刘燕兵. 基于异构社交网络信息和内容信息的事件推荐. 软件学报, 2020, 31(4): 1212–1224. <http://www.jos.org.cn/1000-9825/5544.htm> [doi: 10.13328/j.cnki.jos.005544]
- [3] 许海玲, 吴潇, 李晓东, 阎保平. 互联网推荐系统比较研究. 软件学报, 2009, 20(2): 350–362. <http://www.jos.org.cn/1000-9825/3388.htm> [doi: 10.3724/SP.J.1001.2009.03388]
- [7] 沈苗, 来天平, 王素美, 彭一明, 高志同. 北京大学课程推荐引擎的设计和实现. 智能系统学报, 2015, 10(3): 369–375.
- [9] 黄立威, 江碧涛, 吕守业, 刘艳博, 李德毅. 基于深度学习的推荐系统研究综述. 计算机学报, 2018, 41(7): 1619–1647.
- [12] 厉小军, 柳虹, 施寒潇, 朱柳青, 张亚辉. 基于深度学习的课程推荐模型. 浙江大学学报(工学版), 2019, 53(11): 2139–2145+2162.
- [13] 葛尧, 陈松灿. 面向推荐系统的图卷积网络. 软件学报, 2020, 31(4): 1101–1112. <http://www.jos.org.cn/1000-9825/5928.htm> [doi: 10.13328/j.cnki.jos.005928]
- [20] 刘华锋, 景丽萍, 于剑. 融合社交信息的矩阵分解推荐方法研究综述. 软件学报, 2018, 29(2): 340–362. <http://www.jos.org.cn/1000-9825/5391.htm> [doi: 10.13328/j.cnki.jos.005391]
- [33] 冯永, 张备, 强保华, 张逸扬, 尚家兴. MN-HDRM: 长短兴趣多神经网络混合动态推荐模型. 计算机学报, 2019, 42(1): 16–28.



歹杰(1993–), 男, 博士生, CCF 学生会员, 主要研究领域为智能软件工程, 推荐系统, 图神经网络, 开源软件供应链.



周洋涛(1998–), 男, 硕士生, CCF 学生会员, 主要研究领域为推荐系统, 图神经网络.



李青山(1973–), 男, 博士, 教授, 博士生导师, CCF 杰出会员, 主要研究领域为智能软件工程, 自适应软件演化, 开源基础软件.



杨文勇(1998–), 男, 硕士生, 主要研究领域为推荐系统, 计算机视觉.



褚华(1978–), 女, 博士, 副教授, CCF 专业会员, 主要研究领域为软件工程, 人工智能, 大数据智能化分析技术.



卫彪彪(1999–), 男, 硕士生, 主要研究领域为推荐系统, 计算机视觉.