

融合混合社区与簇级特征的KAN-CTR预测模型

钱忠胜*, 饶雨贤, 吴敏璇, 彭劲强, 王蓉蓉, 许克文

(江西财经大学计算机与人工智能学院, 江西南昌 330013)

摘要: 点击率(Click-Through Rate, CTR)预测是推荐系统的核心任务,其目标是通过用户历史行为与项目特征建模,预测用户对候选项目产生点击行为的概率。然而,现有CTR方法在建模全局交互结构、提取多跳邻居信息及提升高维特征交互学习效率等方面仍存在问题。用户与项目之间的交互通常呈现多层次、强结构化的关联特征,若直接建模则计算量过大且难以捕捉不同层级邻域之间的语义关系,从而限制对潜在语义关联与用户偏好的深入挖掘,而且现有CTR模型多依赖传统神经网络的固定激活函数,在建模高阶非线性特征交互时灵活性不足,易出现特征冗余、泛化能力弱等问题,导致预测精度难以进一步提升。针对这些问题,提出一种融合混合社区划分与簇级特征提取的Kolmogorov-Arnold Networks(KAN)架构CTR预测模型(A KAN-CTR prediction model integrating Hybrid Community and Cluster-level Feature, HCCF-KCTR)。首先,设计一种层次化的混合社区聚类策略,结合粗粒度的全局社区划分与细粒度的簇内优化,将复杂的全局交互关系解构为结构清晰、语义连贯的簇级单元,在保留关键结构信息的同时显著降低建模复杂度。其次,基于全局社区划分结果对多跳邻居进行簇级映射,并引入簇感知注意力池化机制(Attention Pooling),动态评估每跳邻居在簇内及簇间的语义重要性,自适应分配注意力权重,生成高质量的多跳邻居簇级嵌入表示,以充分捕捉用户与项目间的多层次交互特征。最后,利用KAN网络可学习函数替代固定激活函数,构建多个跨跳跨簇特征组合,将复杂的多跳交互特征转化为可解释的低阶函数组合表达,实现结构信息与语义特征的深度融合,进一步提升模型的预测精度与表达能力。在MovieLens、Electronics、Book及Taobao四个真实数据集上与13种主流CTR模型进行对比,实验结果表明,在AUC、GAUC和LogLoss这3个指标上,所提模型HCCF-KCTR相对已有最优基线模型分别平均最少提升2.74%、2.19%、3.68%,验证了其在特征交互建模与预测方面的优越性。此外,本文还通过消融实验、参数敏感性实验以及模型效率实验,验证了各模块的必要性、协同有效性,以及模型在整体效率上的均衡性,进一步阐明了模型具有良好的泛化能力。

关键词: 点击率预测;社区聚类;KAN网络;推荐系统;注意力池化;簇级特征

基金项目: 国家自然科学基金(No.62262025);赣鄱俊才支持计划-主要学科学术和技术带头人培养项目-领军人才(学术类)(No.20243BCE51024)

中图分类号: TP399

文献标识码: A

文章编号: 0372-2112(2026)01-0395-22

电子学报URL: <http://www.ejournal.org.cn>

DOI:10.12263/DZXB.20250993

A KAN-CTR Prediction Model Integrating Hybrid Community and Cluster-Level Feature

QIAN Zhongsheng*, RAO Yuxian, WU Minxuan, PENG Shaoqiang, WANG Rongrong, XU Kewen

(School of Computing and Artificial Intelligence, Jiangxi University of Finance and Economics, Nanchang, Jiangxi 330013, China)

Abstract: click-through rate (CTR) prediction is a core task in recommendation systems, whose goal is to predict the probability that a user will click on a candidate item by modeling the user's historical behaviors and item features. However, existing CTR methods still have problems in modeling global interaction structures, extracting multi-hop neighbor information, and improving the efficiency of high-dimensional feature interaction learning. The interactions between users and items usually exhibit multi-level and strongly structured association characteristics; direct modeling will lead to excessive computational complexity and difficulty in capturing the semantic relationships between different levels of neighborhoods, thereby limiting the in-depth exploration of potential semantic associations and user preferences. Moreover, most existing CTR models rely on fixed activation functions of traditional neural networks, which lack flexibility in modeling high-order nonlinear feature interactions, and are prone to problems such as feature redundancy and weak generalization ability, resulting in difficulty in further improving prediction accuracy. To address these problems, this paper proposes a kolmogorov-arnold networks (KAN)-based CTR prediction model integrating hybrid community division and cluster-level feature extrac-

tion (HCCF-KCTR). Firstly, a hierarchical hybrid community clustering strategy is designed, which combines coarse-grained global community division and fine-grained intra-cluster optimization to decompose complex global interaction relationships into cluster-level units with clear structure and coherent semantics. This strategy significantly reduces the modeling complexity while retaining key structural information. Secondly, based on the results of global community division, multi-hop neighbors are mapped at the cluster level, and a cluster-aware attention pooling mechanism is introduced to dynamically evaluate the semantic importance of each hop of neighbors within and between clusters, adaptively assign attention weights, and generate high-quality cluster-level embedding representations of multi-hop neighbors, so as to fully capture the multi-level interaction characteristics between users and items. Finally, the learnable function of the KAN network is used to replace the fixed activation function, and multiple cross-hop and cross-cluster feature combinations are constructed to convert complex multi-hop interaction features into interpretable low-order function combination, realizing the in-depth fusion of structural information and semantic features, and further improving the prediction accuracy and expressive ability of the model. Comparative experiments are conducted with 13 mainstream CTR models on four real-world datasets, namely MovieLens, Electronics, Book, and Taobao. The experimental results show that, in terms of the three metrics of AUC, GAUC, and LogLoss, the proposed HCCF-KCTR model achieves an average minimum improvement of 2.74%, 2.19%, and 3.68% respectively compared with the existing optimal baseline model, verifying its superiority in feature interaction modeling and prediction. In addition, this work verifies the necessity and synergistic effectiveness of each module as well as the balance of the model in overall efficiency through ablation experiments, parameter sensitivity experiments and model efficiency experiments, further demonstrating that the model has excellent generalization ability.

Keywords: click-through rate prediction; community clustering; kolmogorov-arnold networks; recommender system; attention pooling; cluster-level features

Foundation Item(s): National Natural Science Foundation of China (No.62262025); Jiangxi Poyang Support Program for Talents of China-Major Discipline Academic and Technical Leaders Training Program of Jiangxi Province-Leading Talent (Academic) (No.20243BCE51024)

0 引言

点击率 (Click-Through Rate, CTR) 预测旨在根据用户历史行为及项目静态特征, 精准地估计用户对特定内容的点击概率^[1]。近来, CTR 预测在模型架构与学习机制层面取得显著进展。从早期依赖特征工程的浅层模型, 逐步发展至基于深度学习的结构^[2]。后来, 研究者进一步融合图结构建模思想, He 等人^[3]利用图神经网络 (Graph Neural Network, GNN) 构建了 LightGCN (Light Graph Convolution Network) 模型, 以体现更有效的协同建模。Fan 等人^[4]将 GNN 应用于社交推荐任务中, 探索更加复杂的图结构信息表达。这些方法显著提升了特征表达能力, 但在多阶关系建模与非线性交互表达方面仍存在不足。

CTR 预测场景中的用户-项目交互行为通常构成一个复杂的异构图, 其中包含显式的一阶关系 (如点击、评分) 以及隐式的高阶关联 (如相似用户间的兴趣传递、跨类别项目的隐式耦合)^[5]。在该图结构中, 节点间的连接密度大、跳数跨度大, 直接建模全局交互关系不仅面临高昂的计算成本, 还可能掩盖个体用户的局部行为模式, 从而降低预测精度。例如, 两个用户具有截然不同的兴趣偏好, 但若在全局建模过程中被划入同一嵌入空间, 则可能会引入不相关的信息噪声^[6]。因此, 有必要通过分层聚类机制在全局与局

部层面上重构图结构, 以压缩冗余关系、增强语义可分性, 从而为后续的高效邻居特征学习提供更清晰的结构基础。

在高阶建模方面, 用户的点击行为往往会受到社交网络中多跳邻居的影响。例如, 某用户未直接浏览某款新手机, 但其社交邻居频繁点击该商品的行为可能间接诱发兴趣。Liu 等人^[7]提出的 STAMP (Short-Term Attention/Memory Priority) 模型强调了潜在兴趣与会话级语义间的耦合机制。这类跨节点、跨跳数的跳跃式依赖关系蕴含丰富的语义信息, 对于用户兴趣挖掘与项目语义理解至关重要。然而, 随着跳数的增加, 邻居数量呈指数级膨胀, 导致计算开销激增与噪声传播加剧。现有办法多采用简单聚合或平均策略^[8], 难以区分关键交互路径与无效节点。为此, 需要构建一种簇级的多跳邻居感知机制, 能够在多层次簇结构中动态聚合特征, 突出高相关邻居的语义贡献。

此外, CTR 预测涉及的特征空间高度非线性, 包括用户的历史行为、用户社交关系及上下文等多维交互因素。为有效挖掘这类深层模式, 研究者提出多种融合神经网络结构的 CTR 预测模型。Guo 等人^[9]结合因子分解机与多层感知机 (Multi Layer Perceptron, MLP), 同时建模低阶与高阶特征交互。Zhou 等人^[10]提出 DIN (Deep Interest Network) 模型, 引入局部激活机制以实现对用户兴趣的精细建模, 有效提升建模能

力。然而,传统方法虽结合低阶与高阶特征交叉,但依赖固定激活函数的MLP结构在表达复杂非线性关系时仍显不足^[11-12]。尽管注意力机制^[13]与指数交互层^[14]部分缓解了高阶建模问题,但其固定嵌入空间与高计算代价依然限制了泛化性能。因此,本文提出一种融合混合社区层次结构建模与KAN高阶非线性交互建模的CTR预测框架。该模型以结构层的多级聚类补足特征空间的结构维度,以KAN模块的自适应非线性映射强化特征交互表达,从而在结构可解释性与特征表达能力之间取得平衡,满足复杂CTR场景下的精准预测需求。

针对上述问题,本文提出一种融合混合社区与簇级特征的Kolmogorov-Arnold Networks(KAN)架构CTR预测模型(a KAN-CTR prediction model integrating Hybrid Community and Cluster-level Feature, HCCF-KCTR)。该模型以“结构重构-簇级语义表征-非线性交互”三层融合机制为核心,旨在在图结构稀疏与高维特征交叉之间取得建模平衡。其中引入的KAN网络^[15]通过可学习的单变量函数替代传统激活函数,具备强大的函数拟合能力与结构可解释性,有望为所提模型HCCF-KCTR的特征预测带来新的突破。主要工作与贡献如下。

(1)混合社区的层次化聚类机制。为充分挖掘全局与局部的社区结构特性,设计一种结合Louvain聚类与谱聚类的双层社区划分策略。该模块在用户-项目交互图上实现自上而下的层次化划分:首先粗粒度全局划分以刻画整体协同结构,再在子簇中进行细粒度优化以揭示局部语义差异,从而将复杂的全局交互关系映射为可控的簇级表示,为后续簇级特征提供更优的层次结构基础。

(2)簇级邻居特征提取机制。为缓解多跳邻居带来的噪声与冗余特征,引入一种簇感知的注意力池化机制,该模块利用社区结构对多跳邻居节点进行簇级映射,并结合跳级分组机制与簇级自适应权重调节模块,实现对不同簇群与跳级范围内邻居节点的差异化建模,显著提升局部结构的表达能力与语义聚合效果。

(3)基于KAN网络的CTR模型预测机制。将KAN网络引入CTR预测任务中,充分发挥其在结构分解与复杂非线性交互建模中的表达优势,从而实现了对多跳簇级邻居语义引导下的用户-项目交互关系的精准刻画,弥补传统架构在结构解释性与交叉表达能力方面的不足。

(4)对比实验与消融实验综合分析。在4个真实CTR预测数据域(即MovieLens、Electronics、Book、Tao-bao)上展开对比实验与消融实验分析,结果表明所提模型HCCF-KCTR在AUC、GAUC、LogLoss指标上显著优于现有模型,阐明了其在结构重构、语义表达与预测精

度方面的综合优势,也验证了模型中各个组件的必要性。

1 相关工作

CTR任务核心在于建模用户与项目间复杂的交互关系。聚类与社群划分策略被引入到CTR中对特征进行预处理,有助于发现潜在结构关系并优化图表示,为后续图建模提供更清晰的结构基础。图神经网络因其在高阶结构建模上的优势,被广泛用于CTR中,但随着图结构复杂化,易引入冗余与噪声,影响预测性能。为此,许多模型也尝试通过显式建模多阶特征交互关系,以增强表达能力与可解释性。下面从聚类策略、图神经网络方法与多阶特征交互建模方法三个方面展开分析。

聚类策略利用相似性指标对数据进行簇划分,能有效识别用户与项目间的深层次交互关系和结构模式,有助于优化CTR模型的特征建模与预测能力。Hao等人^[16]通过社区检测技术将兴趣相似的用户和项目归入同一社区,以实现更精细的用户建模。邱林山等人^[17]提出一种双通道协同聚类算法,融合节点属性与拓扑结构信息,有效提升异构图的社区划分质量与推荐性能。此外,传统社群发现方法通常依赖图划分或社区检测方式来挖掘网络中的潜在结构^[18]。钱忠胜等人^[19]创新性地改进社区聚类算法,提高聚类算法对推荐的适应性。Hu等人^[20]将层次化图卷积与结构自适应聚类机制相融合,实现多尺度信息的动态建模。Chen等人^[21]通过在Transformer结构中引入全局图划分信息,并结合局部注意力机制对用户行为序列进行交互建模,从而有效提升结构信息的聚合能力并显著改善推荐性能。

尽管聚类与社群发现策略在挖掘静态图结构中的潜在关系方面取得一定成果,但现有策略往往侧重于全局社区或局部簇群的单一尺度建模,缺乏多粒度的融合机制,难以有效捕捉用户-项目交互中的多层次与多跳结构特征。同时,聚类与图划分过程通常独立于CTR模型作为预处理,仅将此过程的结果输出当作静态标签以用于特征初始化或数据分组,未能与CTR预测后续任务深度融合,导致所提取结构信息难以充分服务于特征交互建模。这些问题在实际预测场景中显著制约了CTR模型对深层行为模式与结构语义的精准建模。

图神经网络方法通过对用户与项目的图结构进行建模,充分捕捉其中的隐含语义信息,因其具有强大的信息聚合能力,可有效地提升CTR预测的准确性和推荐效果^[22]。He等人^[3]提出的LightGCN模型,通过GNN架构有效捕捉用户与项目间的协同关系,显著提升预测效果。李邵莹等人^[23]结合图卷积网络

(Graph Convolutional Networks, GCN)提出一种基于图嵌入的邻居建模方法,更精确地捕捉多跳邻居信息对用户行为的影响。尽管这些方法在某些场景下取得良好效果,但它们在处理大规模数据时的计算开销较大,且在捕捉多维特征和高阶邻居关系时仍存在一定挑战。Wu 等人^[24]提出的基于注意力池化的多跳邻居建模方法,通过加权邻居节点有效降低噪声和冗余特征,提高模型精度。Hou 等人^[25]提出一种基于邻居分组与自适应加权的特征融合方法,能在多跳邻居关系建模中有效提升计算效率,同时增强特征融合精度。Guo 等人^[26]引入分层结构,在建模多跳邻居时降低计算复杂度,同时提高模型的预测能力。陈荣元等人^[27]结合上下文感知的位置动态注意力机制挖掘会话项目重要程度,以此精准把握用户实时兴趣、辨别项目语义差异。

尽管基于 GNN 的方法在建模高阶交互方面取得一定成效,然而它们对多跳邻居关系缺乏精细化建模,往往采用统一的传播与聚合策略,难以区分不同跳数、不同簇群邻居的重要性差异,从而限制关键语义路径的表达能力。同时,这些方法在邻居特征融合过程中未能有效控制语义冗余与结构噪声,导致嵌入表示易受干扰,削弱了模型的判别性能。此外,部分模型仅关注局部特征聚合,忽视了跨簇群间的上下文协同作用,难以捕捉复杂用户行为背后的潜在结构模式。

多阶特征交互建模方法旨在有效捕捉点击率预测任务中高维稀疏特征间的复杂交互关系。早期 CTR 模型主要通过显隐式方式捕捉特征间的低阶交互关系,模型(如逻辑回归和因子分解机^[28])引入归纳偏置有效建模一阶与二阶交互,提升模型对协同关系的表达能力。随着深度学习的发展,MLP 被引入 CTR 模型中以学习非线性交互关系。Guo 等人^[9]将因子分解机结构与 MLP 结合,在无需特征工程的前提下捕捉低阶与高阶交互。Qu 等人^[29]引入内积、外积层以建模范特征乘积关系,并借助 MLP 进一步融合语义。然而,传统 MLP 结构基于隐式建模机制,难以直观解释交互过程,且对高阶交互的表达能力受限。为此,研究者提出多种显式建模结构以增强特征表达能力,Lian 等人^[11]提出压缩交互网络(Compressed Interaction Network, CIN),通过逐层构建多阶特征组合并保留原始维度交互信息,一定程度上提升了建模效率与表达力。Xiao 等人^[30]结合注意力机制,以加权方式学习不同特征间的重要性,进一步增强对复杂关系的辨别能力。在此基础上,Transformer 架构被引入 CTR 预测任务中,以突破传统神经网络在特征依赖建模中的局限。Song 等人^[31]率先应用自注意力机制以实现多阶特征交互的自动学习;Wang 等人^[32]通过自注意力权

重可视化揭示用户兴趣演化过程;Zhang 等人^[33]借助层级特征分解机制对推荐逻辑提供显式解释,使 Transformer 在保证预测精度的同时具备良好的可解释性;Wang 等人^[34]提出以平衡显式低阶与隐式高阶特征交互,提高 CTR 预测模型的表达能力与性能;Dilbaz 等人^[35]与 Han 等人^[36]在此基础上融合多层注意力与位置编码机制,增强特征交叉表达能力并优化全局建模效果。总体而言,Transformer 在 CTR 任务中的应用不仅提升预测性能,为模型解释性提供了有效途径,也为后续高阶特征交互研究提供了理论基础。

尽管基于 Transformer 的多阶交互模型在特征表达与可解释性方面取得了显著进展,其建模结构仍依赖于预定义的嵌入空间来表示特征,容易导致不同语义特征被映射至相似区域,从而引发语义混淆与特征失真。此外,其交互过程中大多缺乏显式的结构解释机制,使得模型决策逻辑难以理解与优化。近来,新兴的 KAN^[15]通过可学习的函数库替代固定激活函数,实现结构可解释的函数拟合,在复杂非线性交叉表达中展现强大能力。Shi 等人^[37]首次提出基于 KAN 架构的 CTR 任务,引入成对乘法机制(pairwise multiplicative mechanism),引导网络显式学习特征间的乘法交互关系,突破传统模型对固定激活函数和嵌入空间的依赖,从而增强表达能力与可解释性。然而,该方法主要聚焦于特征层面的交互表达,未充分考虑用户与项目间结构关系建模,忽略了在 CTR 任务中普遍存在的图结构交互特性;另外,其特征交互建模仍基于全局嵌入空间展开,未能结合上下文语义或邻居结构进行局部差异化建模,在面对异质特征和多层次兴趣关系时易降低表达精度。

综上分析,现有 CTR 预测方法在多层次结构信息建模、特征交互建模方面仍存在多粒度信息融合缺失、多路径信息提取能力弱,以及高阶关系建模不充分等问题。基于此,提出一种融合混合社区与簇级特征的 KAN 架构 CTR 预测模型 HCCF-KCTR。首先,该模型通过混合社区划分的层次化聚类机制,先进行宏观社区压缩,再执行细粒度子簇优化,有助于动态细化大规模数据中的结构关系,生成用户簇和项目簇,从而刻画大规模交互图中的多层结构关系,并为特征传播提供全局-局部统一的簇级结构先验。其次,簇级邻居特征提取模块基于该结构基础,借助注意力池化机制在簇层级实现跨簇依赖建模与语义增强,有效提升局部表示的精度与稳定性。最后,KAN-CTR 预测模块以结构语义基础为引导,通过 KAN 层的非线性交互映射实现多跳嵌入的跨空间融合,在高维特征空间中充分捕捉复杂的结构依赖与语义关联,从而实现更加精准且可解释的 CTR 预测。

2 HCCF-KCTR 预测模型的构建

为便于阐述,对文中的符号进行说明,表1所示。
下面先给出本文模型 HCCF-KCTR 的整体框架,

表1 主要符号及含义

Table 1 Main symbols and their meanings

符号	含义
G	用户-项目交互图
U, V	目标用户集、项目集
Q	模块度
ΔQ	模块度增益
ϕ_c^{in}	簇 c 内部边数量
$\phi_c^{\text{user}}, \phi_c^{\text{item}}$	簇 c 内用户、项目节点的度数
k	节点度数
C_u, C_v	粗粒度中用户簇集与项目簇集
A_u^i	第 i 个用户簇的邻接矩阵
D_u^i	第 i 个用户簇的度矩阵
\tilde{C}_u, \tilde{C}_v	细粒度中用户簇集与项目簇集
$e_b^{(l),c}$	邻居 b 在第 l 跳的簇 c 内的嵌入表示
$\alpha_{b,p}^{(l),c}$	邻居 b 对目标节点 p 在第 l 跳的簇 c 内注意力权重
$\beta_p^{(l),c}$	目标节点 p 在第 l 跳的簇 c 内簇级注意力权重
$e_u^{(l)}, e_v^{(l)}$	目标用户 u 、项目 v 的第 l 跳表示
$W^{(l)}$	第 l 跳邻居的加权系数
\hat{y}	预测评分

如图1所示,主要包含如下几个模块:

(1)混合社区层次聚合模块(见图①),挖掘全局与局部结构信息。该模块在用户-项目交互图基础上引入双层混合社区划分策略。先进行粗粒度的全局社区划分,以把握整体交互结构;再对簇内子图执行细粒度优化,提升局部结构建模能力。通过该机制实现对全局交互图的有效简化与结构重构,增强结构信息的可控性和表达能力,为后续簇级特征提取建立了语义一致的结构先验。

(2)簇级邻居特征提取模块(见图②),获取高阶邻居表示。基于结构聚类结果,将多跳邻居映射至相应簇级结构中。通过引入注意力池化机制,动态评估每跳邻居在簇内及簇间的语义重要性,实现多层次、多尺度的邻居表示学习,从而有效提升模型的全局与局部表达,以及语义聚合能力。

(3)KAN-CTR 预测模块(见图③),融合高维特征。为更充分地挖掘多簇嵌入之间的复杂非线性关系,改进 KAN 网络模块,充分发挥其在结构分解与复杂非线性交互建模中的表达优势,将 CTR 任务中的高维复杂特征交互关系分解为多组低阶特征组合表达,显著增强模型在特征融合、非线性交叉表达与结构可解释性方面的表现,最终 KAN-CTR 预测模块与前两层结构相结合,形成从结构重构、语义提取到非线性交互的统一建模框架,实现了 CTR 任务中的结构驱动与语义增强式预测。

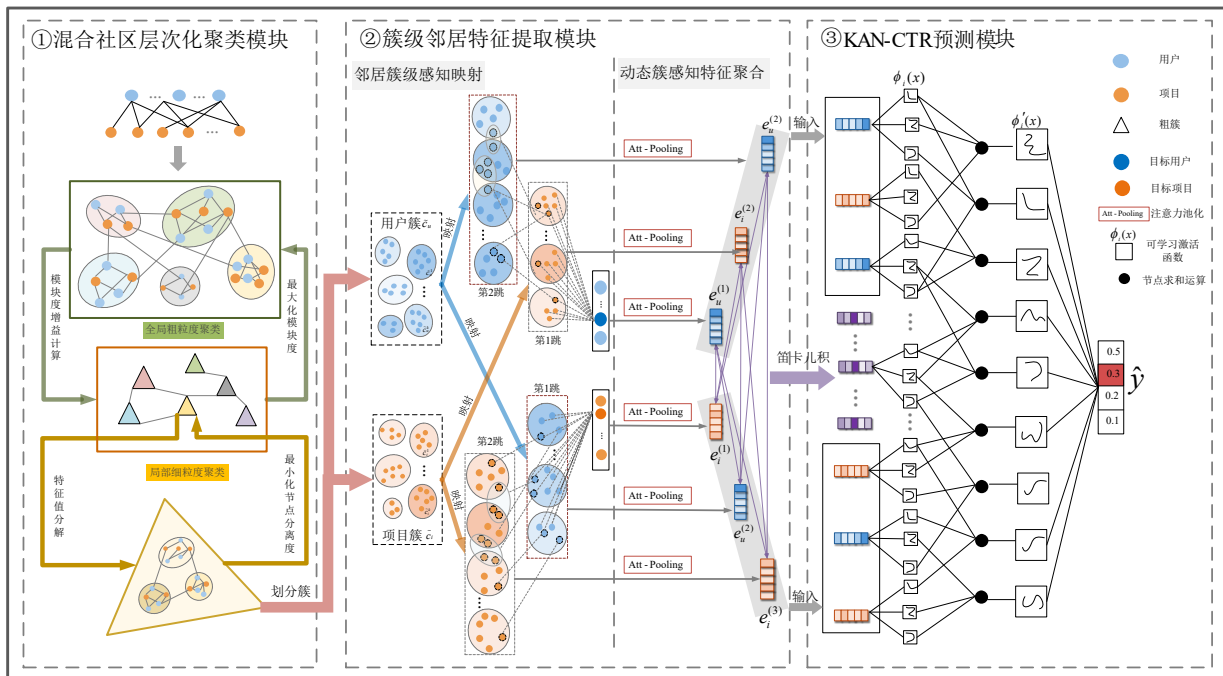


图1 HCCF-KCTR 模型的整体框架

Figure 1 The whole framework of HCCF-KCTR model

2.1 基于混合社区的层次化聚类

在大规模用户-项目交互图中,如何有效地将复杂的全局结构划分为可控的局部簇级结构,是提升系统结构建模能力的关键。由于初始聚类往往存在较高的异质性,即同一簇中可能包含兴趣或特征差异显著的节点,因此有必要在聚类结果基础上进一步细化结构,以提升聚类的一致性与语义表达。

尽管所提出的混合社区划分在训练前执行,但其功能并非传统意义上的独立预处理,而是作为模型结构的重要组成部分贯穿后续预测任务。具体而言,Louvain负责压缩全局图结构冗余,而谱聚类进一步细化簇内语义,两者共同构成多粒度的重要结构先验,使模型在多跳特征聚合与非线性交互中长期生效。该结构与后续模块紧耦合的设计可弥补传统方法结构信息利用不足的问题,为后续簇级语义建模提供了层次化结构先验指导,也为模型提供更具可解释性和稳定性的结构化表达能力。

2.1.1 全局粗粒度聚类

Louvain算法是一种经典且高效的模块度(Modularity)最大化方法,其目标是通过最大化模块度得到聚类结果^[38]。模块度划分的核心思想是比较社区内部的实际边数和随机连接的期望边数,以此衡量划分结果是否优于随机划分,从而挖掘图中的潜在聚集结构。为捕捉用户-项目交互图中的宏观结构模式,我们采用改进的Louvain算法进行全局聚类,在用户-项目交互图上对用户和项目进行共聚,形成初步的社区划分。在改进的Louvain算法中,二部图的每个节点被表示为一个新的逻辑节点,它同时具有用户节点和项目节点的结构信息。例如,一个度为 k_u 的用户节点 u 被重构为一个逻辑节点,它的逻辑信息包含一个出度为 k_u^{out} 的用户节点和一个入度为零的项目节点,且在度为 k_v 的项目节点中有一条与该用户节点 u 连接的权重为零的内部边。

对于有向用户-项目二部图,我们通过模块度 Q 将图划分为若干结构紧密的簇,如式(1)所示。

$$Q = \frac{1}{2m} \sum_{c \in C} \sum_{a_{uv} \in A_{uv}} a_{uv} \frac{\left(\sum_{u \in c} k_u^{\text{out}} \right) \cdot \left(\sum_{v \in c} k_v^{\text{in}} \right)}{m} + \sum_{a_{vu} \in A_{vu}} a_{vu} - \frac{\left(\sum_{v \in c} k_v^{\text{in}} \right) \cdot \left(\sum_{u \in c} k_u^{\text{out}} \right)}{m} \quad (1)$$

其中, C 为簇集; m 是图中总边数; A_{uv} 为用户-项目图构建的邻接矩阵,若用户 u 与项目 v 存在交互,则 $a_{uv} = a_{vu} = 1$,否则为0; k_u^{out} 与 k_v^{in} 分别表示用户 u 的出度(用户 u 射出的边数,即用户点击了多少个项目)与项目 v 的入度(指向项目 v 的边数,即有多少用户点击了该

项目)。

对于无向用户-项目二部图,从用户节点 u 到项目节点 v 的边等于来自相反方向的边。由于边只存在于用户节点和项目节点之间,我们引入每个簇内的实际边数 φ_c^{in} ,使得每条边的贡献都能体现在节点的划分上。在每个簇 $c \in C$ 中, φ_c^{user} 和 φ_c^{item} 分别表示所有用户节点和项目节点的总度数,如式(2)所示。

$$\begin{aligned} \varphi_c^{\text{in}} &= \sum_{u,v \in C} a_{uv}, \\ & \quad a_{uv} \in A_{uv} \\ \varphi_c^{\text{user}} &= \sum_{u \in c} k_u^{\text{out}}, \\ \varphi_c^{\text{item}} &= \sum_{v \in c} k_v^{\text{in}} \end{aligned} \quad (2)$$

因此,式(1)可被改写为更为简洁的模块度计算过程,如式(3)所示。

$$Q = \frac{1}{m} \sum_{c \in C} \left(\varphi_c^{\text{in}} - \frac{\varphi_c^{\text{user}} \cdot \varphi_c^{\text{item}}}{m} \right) \quad (3)$$

为评估簇划分结构在节点迁移过程中的变化,我们将一个用户节点 u 从其原簇迁移到目标簇 c 中,簇 c 内部边数变化如式(4)所示。

$$\begin{aligned} \hat{\varphi}_c^{\text{in}} &= \varphi_c^{\text{in}} + k_{v,c}^u, \\ \hat{\varphi}_c^{\text{user}} &= \varphi_c^{\text{user}} + k_u \end{aligned} \quad (4)$$

其中, $k_{v,c}^u$ 表示用户节点 u 与簇 c 中所有项目节点 v 之间的边数之和。

在每次迭代过程中,Louvain算法通过局部搜索最大的模块度增益,进而提取更具结构意义的簇级特征关系。该增益可通过迁移节点前后簇结构的模块度差异计算,如式(5)所示。

$$\begin{aligned} \Delta Q &= Q_{\text{after}} - Q_{\text{before}} \\ &= \frac{1}{m} \left[\left[\hat{\varphi}_c^{\text{in}} - \frac{(\hat{\varphi}_c^{\text{user}}) \cdot \varphi_c^{\text{item}}}{m} \right] - \left[\varphi_c^{\text{in}} - \frac{(\varphi_c^{\text{user}}) \cdot \varphi_c^{\text{item}}}{m} \right] \right] \\ &= \frac{k_{v,c}^u}{m} - \frac{k_u \cdot \varphi_c^{\text{item}}}{m^2} \end{aligned} \quad (5)$$

同理,对于项目节点 v 需迁入簇 c 中,模块化增益可用类似式(5)的方式计算。在模块度收敛后,即可获得初步的粗粒度簇。通过进一步划分用户和项目节点,分别得到初始用户簇集 $C_u = \{c_u^1, c_u^2, \dots, c_u^n\}$ 与项目簇集 $C_v = \{c_v^1, c_v^2, \dots, c_v^n\}$ 。

2.1.2 局部细粒度聚类

为挖掘簇内更细粒度的结构模式,我们在基于Louvain改进算法获得的初始簇划分基础上,进一步对粗粒度的用户簇集 C_u 和项目簇集 C_v 中的每一个簇,引入谱聚类(spectral clustering)方法进行局部细化。此步旨在依据节点在簇内的局部结构关系,识别更精

细的社区划分特征,从而实现多层次、细粒度的簇结构建模。

谱聚类通过构造图的拉普拉斯矩阵(laplacian matrix),对簇内节点进行嵌入与划分,以优化节点间的模块分离度(modularity gap),该方法可确保每个簇内节点具有较高的结构相似性,同时增强簇间区分性。具体而言,对于第*i*个用户簇 c_u^i ,我们提取其局部子图 $G(c_u^i)=\{V_i, E_i\}$,其中 V_i 表示簇 c_u^i 中的用户节点集, E_i 表示这些用户节点间的连接边集。我们据此构建该簇的邻接矩阵 $A_u^i \in \mathbb{R}^{n \times n}$ 和对应的度矩阵 D_u^i 。其中,若用户 u_1 与 u_2 相连,则 $a_{u_1, u_2}^i=1$;在相应的度矩阵中,每一对角元素为 $D_{u_1, u_1}^i = \sum_{u_1, u_2 \in E_i} a_{u_1, u_1}^i$ 。

在获得第*i*个簇的邻接矩阵与度矩阵后,我们进一步构造该簇的归一化拉普拉斯矩阵 L_{sym}^i ,用于后续的谱嵌入计算与节点划分,如式(6)所示。

$$L_{\text{sym}}^i = D_{u_1, u_2}^i^{-\frac{1}{2}} I D_{u_1, u_2}^i^{-\frac{1}{2}} = I - \left(D_{u_1, u_2}^i \right)^{-\frac{1}{2}} A_u^i \left(D_{u_1, u_2}^i \right)^{-\frac{1}{2}} \quad (6)$$

其中, I 为单位矩阵。该矩阵 L_{sym}^i 反映了簇内图结构的局部连接模式,其特征值和特征向量反映了用户节点的聚类潜力。谱聚类的关键是对拉普拉斯矩阵进行特征值分解,如式(7)所示。

$$L_{\text{sym}}^i U^i = \lambda_i u_i \quad (7)$$

其中, λ_i 为特征值, u_i 是对应的特征向量。我们选取前*k*个最小特征值对应的特征向量(最优划分),构成低维特征矩阵 $U^i \in \mathbb{R}^{n \times k}$ (n 为簇内节点数),表示簇中每个节点在特征空间中的投影。具体地,第*i*个簇内节点的低维向量表示如式(8)所示。

$$u_i = (u_{i1}, u_{i2}, \dots, u_{ik}) \quad (8)$$

随后,我们将矩阵 U^i 的每一行视为一个节点的向量表示,并对这些向量使用K-means聚类算法进行划分。K-means通过遍历各簇的簇内样本点与其相应簇中心间的平方误差(Within-Cluster Sum of Squares, WCSS)最小化来实现优化,如式(9)所示。

$$Q_{\text{WCSS}} = \sum_{i=1}^k \sum_{x \in C_i} \|x - u_i\|^2 \quad (9)$$

最终,我们得到第*i*个粗粒度簇 c_u^i 的细粒度划分,如式(10)所示。

$$\tilde{C}_u = \{\tilde{c}_u^1, \tilde{c}_u^2, \dots, \tilde{c}_u^k\} \quad (10)$$

对于每个粗粒度用户簇 c_u^i ,谱聚类返回对应的细粒度子簇集 $\tilde{C}_u = \{\tilde{c}_u^1, \tilde{c}_u^2, \dots, \tilde{c}_u^k\}$ 。同理,对每个粗粒度项目簇 c_v^i 亦可获得对应的细粒度子簇集 $\tilde{C}_v = \{\tilde{c}_v^1, \tilde{c}_v^2, \dots, \tilde{c}_v^k\}$ 。细粒度子簇集更准确表示特征空间结构相似的用户或项目节点。

综上分析,通过引入混合社区的层次化聚类机

制,我们在原始用户-项目交互图的基础上,融合粗粒度的全局簇划分与细粒度的局部结构划分,实现交互关系的分层表示建模。该方法不仅提升模型对复杂结构信息的建模能力,而且有效增强簇间关系的可解释性和可控性,从而以多粒度方式揭示用户与项目之间的潜在语义关联。基于混合社区的层次化聚类过程具体见算法1。

算法1 混合社区的层次化聚类

输入:用户-项目交互图 $G=(U, V, E)$

输出:粗粒度用户簇集与项目簇集 C_u, C_v ,细粒度用户簇集与项目簇集 \tilde{C}_u, \tilde{C}_v

Begin

1. 初始化图中每个节点为独立社区;
2. $Q \leftarrow 0$; //初始化模块度
/* 全局粗粒度聚类 */
3. For each $u \in U$
4. 计算用户节点 u 迁入簇 c 的模块度 Q ; //见式(3)
5. 更新簇 c 内边数与各用户节点度数; //见式(4)
6. $\Delta Q \leftarrow Q_{\text{after}} - Q_{\text{before}}$; //计算模块增益;见式(5)
7. If $\Delta Q = \Delta Q_{\text{max}}$ then: //判断模块度是否最大
8. 更新用户簇集 C_u ;
9. End if
10. End For
11. 对项目簇 C_v 重复步骤3~10,得到粗粒度项目簇集 C_v ;
/* 局部细粒度聚类 */
12. For each $c_u^i \in C_u$
13. 构建子图 $G(c_u^i)$,获取邻接矩阵 A_u^i 与矩阵 D_u^i ;
14. 计算归一化拉普拉斯矩阵 L_{sym}^i ; //见式(6)
15. 特征值分解得到嵌入矩阵 U^i ; //见式(7)
16. 最小化簇内方差; //见式(9)
17. 对 U^i 应用K-means聚类得到细粒度用户簇 \tilde{c}_u^k ;
//见式(10)
18. End For
19. 生成粗粒度用户簇集 \tilde{C}_u ;
20. 对粗粒度项目簇集 C_v 重复12~18,得到细粒度项目簇集;
21. Output $C_u, C_v, \tilde{C}_u, \tilde{C}_v$; //粗粒度簇集和细粒度簇;

End

在算法1中,第3~10行是全局粗粒度聚类模块,通过改进Louvain算法进行全局聚类,在用户-项目交互图上对用户和项目进行共聚,形成初步的粗粒度社区划分;第12~18行是局部细粒度聚类模块,通过簇内的进一步细化,得到更精准的用户簇、项目簇。

2.2 基于簇级邻居的特征提取

为更充分利用簇内与簇间多跳邻居结构特征信息,所提模型HCCF-KCTR基于结构层输出的社区划分结果,将目标节点的多跳邻居映射至相应簇中,形成簇感知邻域结构;随后引入分层注意力池化,动态计算邻

居节点在簇内及簇间的影响力权重,突出高相关邻居并抑制噪声传播。在邻域范围的设定上,本文基于图结构 CTR 预测领域的通用实践与模型稳定性考虑,采用 1-2 跳邻域作为簇级特征提取的基础结构单元。

2.2.1 簇级邻居感知映射

我们通过跳级遍历方式提取用户或项目节点的多层次邻居,提取目标节点 p 的 1 跳直接邻居和 2 跳间接邻居,如式 (11) 所示。

$$\begin{aligned} N_p^{(1)} &= \{n_{p,1}^{(1)}, n_{p,2}^{(1)}, \dots, n_{p,i}^{(1)}\}, \\ N_p^{(2)} &= \{n_{p,1}^{(2)}, n_{p,2}^{(2)}, \dots, n_{p,j}^{(2)}\} \end{aligned} \quad (11)$$

其中, $N_p^{(1)}$ 和 $N_p^{(2)}$ 分别为目标节点 p 的 1 跳和 2 跳邻居节点集。

在获取多跳邻居集之后,我们基于层次化聚类模块的社区划分结果,把每个节点及其邻居分配到对应的簇。相似的用户(如高活跃或低活跃)和相似的项目(如电子产品类或服饰类)被划入相应簇,形成结构上的簇级关联。每一跳对应的簇级邻居集可表示为如式 (12) 所示。

$$\begin{aligned} \tilde{C}_p^{(1)} &= \{\tilde{c}_{p,1}^{(1)}, \tilde{c}_{p,2}^{(1)}, \dots, \tilde{c}_{p,h}^{(1)}\}, \\ \tilde{C}_p^{(2)} &= \{\tilde{c}_{p,1}^{(2)}, \tilde{c}_{p,2}^{(2)}, \dots, \tilde{c}_{p,k}^{(2)}\} \end{aligned} \quad (12)$$

其中, $\tilde{C}_p^{(1)}$ 与 $\tilde{C}_p^{(2)}$ 分别表示目标节点 p 的第 1 跳、第 2 跳邻居中的簇集。

2.2.2 簇感知注意力池化

在多跳邻域的聚合中,不同邻居节点对目标节点的贡献可能存在显著差异。Bei 等人^[39]使用平均池化对所有邻居等权处理,尽管在计算上更为高效,但却忽略了邻居间影响力的差异,难以有效捕捉关键邻居所蕴含的重要语义信息。例如,当用户最近点击了“苹果耳机”和“运动鞋”时,与其 6 个月前点击的“冰箱”相比,这些近期的交互显然具有更高的行为相关性。然而,平均池化无法体现这种差异,可能引入信息冗余。为此,我们引入注意力池化机制,动态调整邻居嵌入的聚合权重,更精准地建模多跳簇结构中的异质信息传播过程。在簇级注意力机制中,我们保持所有节点与簇级嵌入向量的维度一致(均为 d),以确保在簇内注意力、簇间注意力、跨跳特征融合及 KAN 层非线性交互过程中能实现结构一致、维度对齐的特征传播。

具体而言,对于目标节点 p 在不同跳数 l 的邻域中,其邻居节点可能分布在多个簇中。针对某一簇 \tilde{c} 内的所有邻居节点,其簇级嵌入表示可按式 (13) 进行计算。

$$e_p^{(l),\tilde{c}} = \sum_{b \in \tilde{c}} \alpha_{b,p}^{(l),\tilde{c}} \cdot e_b^{(l),\tilde{c}} \quad (13)$$

其中,目标节点 p 的初始嵌入维度为 d 。 $\alpha_{b,p}^{(l),\tilde{c}}$ 是簇 \tilde{c} 内

邻居节点 b 对目标节点 p 在第 l 跳的注意力权重,初始值为簇 \tilde{c} 内每一邻居节点的注意力权重的平均值。 $e_b^{(l),\tilde{c}}$ 表示邻居节点 b 的嵌入表示,维度与目标节点嵌入一致为 d 。

为衡量邻居节点 b 对目标节点 p 的重要性,权重 $\alpha_{b,p}^{(l),\tilde{c}}$ 采用可训练参数 W_1, W_2 和偏置 t 构成的两层注意力网络学习,如式 (14) 所示。

$$\alpha_{b,p}^{(l),\tilde{c}} = \frac{\exp\left(\text{LeakyReLU}\left(W_2 \cdot \left(W_1 \cdot \left(e_p^{(0)} \odot e_p^{(l),\tilde{c}} + t\right)\right)\right)\right)}{\sum_{b' \in \tilde{c}} \exp\left(\text{LeakyReLU}\left(W_2 \cdot \left(W_1 \cdot \left(e_p^{(0)} \odot e_p^{(l),\tilde{c}} + t\right)\right)\right)\right)} \quad (14)$$

其中, $e_p^{(0)}$ 是目标节点 p 的原始嵌入表示; \odot 表示对簇 \tilde{c} 内邻居节点的 Hadamard 逐元素积,表示目标节点与其邻居间的特征交互。激活函数 $\text{LeakyReLU}(\cdot)$ 用于增强模型对非线性交互模式的表达能力。

同理,我们可获得第 l 跳中其他不同簇内聚合表示。为进一步整合多个簇之间的信息,我们引入簇级注意力机制,对不同簇的聚合表示进行加权,得到目标节点在第 l 跳的最终簇感知表示,如式 (15) 所示。

$$e_p^{(l)} = \sum_{\tilde{c} \in \tilde{C}_p^{(l)}} \beta_p^{(l),\tilde{c}} \cdot e_p^{(l),\tilde{c}} \quad (15)$$

其中,节点 p 对簇 c 在第 l 跳邻域的簇内聚合嵌入维度仍保持为 d 。 $\beta_p^{(l),\tilde{c}}$ 是簇 \tilde{c} 对目标节点 p 在第 l 跳的注意力权重,如式 (16) 所示。

$$\beta_p^{(l),\tilde{c}} = \frac{\exp\left(W_c \cdot e_p^{(l),\tilde{c}}\right)}{\sum_{\tilde{c}' \in \tilde{C}_p^{(l)}} \exp\left(W_c \cdot e_p^{(l),\tilde{c}'}\right)} \quad (16)$$

其中, W_c 表示一个可训练的注意力权重向量,用于为每个簇的嵌入进行线性变换操作。

簇级注意力机制允许模型根据不同簇群的重要性对多跳邻域信息进行动态建模,从而有效提升目标节点在簇感知空间中的表示能力与表达精度。

通过上述设计的簇内与簇间的注意力加权机制,我们能够动态建模不同邻居及簇群对目标节点表示的贡献程度,不仅有效缓解信息冗余,还能突显关键交互行为,从而提升特征表示的准确性与表达能力。基于簇级邻居的特征提取过程见算法 2。

在算法 2 中,第 1~3 行将第 1 跳邻居根据聚类结果划分为若干细粒度簇;第 4~10 行分别对每个簇进行簇内注意力聚合;第 11 行结合注意力池化进一步实现簇间注意力融合,最终得到每一跳的簇感知嵌入表示,第 13 行为输出。

2.3 基于 KAN-CTR 的模型预测

在前两层完成了结构划分与簇级语义聚合后,表达层旨在对多跳簇级嵌入进行高阶非线性交互建模,

算法 2 基于簇级邻居的特征提取

输入: 目标节点 p , 多跳邻居集 $N_p^{(l)}$, 簇划分集 $\tilde{C}_p^{(l)}$

输出: 目标节点的多跳簇感知嵌入表示 $\{e_p^{(1)}, e_p^{(2)}\}$

Begin

1. For $l \leftarrow 0$ to 2;

2. 提取目标节点的第 l 跳邻居集 $N_p^{(l)}$; // 见式(11)

3. 根据社区划分结果确定对应簇级邻居集; // 见式(12)

4. For each $c \in \tilde{C}_p^{(l)}$

5. For each $b \in \tilde{c}_p^{(l)}$

6. 获取节点级注意力权重; // 见式(14)

7. 获取加权聚合邻居表示; // 见式(13)

8. End For

9. 对所有簇级嵌入进行簇间注意力加权聚合; // 见式(16)

10. End For

11. 获取第 l 跳簇感知嵌入表示 $e_p^{(l)}$; // 见式(15)

12. End For

13. Output 多跳簇感知嵌入表示 $e_p^{(1)}, e_p^{(2)}$;

End

以生成最终的 CTR 预测结果。KAN 网络基于可学习的一元激活函数设计,能够对每一维输入特征执行独立的非线性变换,并通过多层线性组合对这些变换结果进行融合,从而灵活建模高阶的复杂特征交互关系。然而,原始 KAN 主要为无先验结构输入的设计,其建模过程未考虑 CTR 场景中特有的多跳结构先验与簇级语义差异。因此,本文在保持 KAN 结构完整的前提下,对其输入组织与交互路径进行了任务级适配,以更好地匹配簇级特征建模需求。

具体而言,我们在模型预测阶段引入 KAN-CTR 预测模块,通过改进的 KAN 网络的分解式非线性结构,对多维簇嵌入执行逐维映射与可学习组合。在该模块中,先对来自目标节点不同跳数(0~2 跳)的簇级邻居嵌入执行拼接与笛卡儿积操作,以构建各种跨跳特征组合,从而形成高维交互特征空间。随后,将原始跳级嵌入与其生成的跨跳交叉特征共同输入至 KAN-CTR 模块。该预测机制在缓解传统 MLP 的梯度消失与冗余参数问题的同时,不仅能提升模型在捕捉异质簇间非线性依赖结构上的能力,也可增强其整体的预测性能与泛化效果。

由簇级邻居的特征提取模块可获得目标用户 u 与目标项目 v 的多跳簇级嵌入表示 $e_u^{(l)}, e_v^{(l)} (l = 0, 1, 2)$ 以用户节点 u 为例, $e_u^{(0)}$ 表示 u 的自身嵌入, $e_u^{(1)}$ 表示其第 1 跳邻居(兴趣项目)嵌入, $e_u^{(2)}$ 表示其第 2 跳邻居(相似兴趣的用户)嵌入。

为保留节点局部结构感知能力,我们构建目标用户与目标项目不同跳的跨跳交互表示,先将上述 6 个簇级嵌入表示拼接为一个整体特征表示 ε , 如式(17)

所示。

$$\varepsilon = [e_u^{(0)} \| e_u^{(1)} \| e_u^{(2)} \| e_v^{(0)} \| e_v^{(1)} \| e_v^{(2)}] \quad (17)$$

为进一步捕捉用户与项目在不同跳数间的潜在语义耦合关系, KAN-CTR 模块引入跨跳交叉交互机制, 如式(18)所示。

$$S = \{e_u^{(l)} \odot e_v^{(l)} | l \in \{0, 1, 2\}\} \quad (18)$$

其中, \odot 表示对多跳簇级嵌入的 Hadamard 逐元素积, 以体现用户与项目在同一跳、不同跳层级结构下的语义耦合。最终的融合输入向量 \mathbf{x} 由原始拼接向量 ε 与交叉特征集 S 拼接而成, 如式(19)所示。

$$\mathbf{x} = \text{concat}(\varepsilon, S) \quad (19)$$

该融合向量 \mathbf{x} 作为初始输入向量 $\mathbf{z}^{(0)}$ 被送入 KAN-CTR 模块, 其中包含用户和项目节点在不同层级簇结构中的多跳嵌入特征及其交互关系。KAN-CTR 模块由若干堆叠层构成, 每一层包含一组可学习的单变量非线性变换数与线性组合结构, 第 d 层输入向量为 $\mathbf{z}^{(d-1)}$, 如式(20)所示。

$$\mathbf{z}^{(d)} = \mathbf{W}^{(d)} \cdot \phi^{(d)}(\mathbf{z}^{(d-1)}) + \mathbf{b}^{(d)} \quad (20)$$

其中, $\mathbf{W}^{(d)}, \mathbf{b}^{(d)}$ 分别为 d 层的权重矩阵与偏置向量; $\phi^{(d)}$ 表示在第 d 层中对每一维输入进行非线性变换。具体地, KAN 网络中第 i 维输入为一组 B 样条基函数的加权线性组合, 如式(21)所示。

$$\phi_i(x) = \sum_{j=1}^{g+r} c_{ij} \cdot B_{j,r}(x_i) \quad (21)$$

其中, x_i 为当前输入向量在第 i 个维度的取值, 这一维度来自目标用户或项目节点的某跳簇级嵌入, 或者用户与项目间的跳级交互结果; $B_{j,r}(x_i)$ 为第 j 个 r 阶 B 样条基函数, 具备良好的平滑性与可调节阶数, 能够自适应拟合输入特征在该维度上的复杂分布, 以适配用户兴趣和项目类别之间的高阶交互; c_{ij} 表示该 B 样条在第 i 个维度映射函数组合中的权重; g 表示节点间的间隔数, $(g+r)$ 为 B 样条基函数数量(每个阶数为 r), 通过调整 B 样条个数 $(g+r)$ 和阶数 r , 可灵活控制模型在每维特征上的拟合。将 B 样条基函数引入每一维输入的非线性变换中, KAN-CTR 能自适应建模用户与项目间的高阶非线性交互, 捕捉多跳簇结构的精准语义, 从而增强模型的表示能力与泛化能力。

通过上述加权机制, KAN-CTR 模块能灵活实现对输入特征的非线性变换与组合, 有效捕捉目标用户与项目间多跳簇级、跨跳级邻居关系中的深层次交互特征。最终, 模块输出的融合表示被输入预测层, 用于生成 CTR 任务预测值, 如式(22)所示。

$$\hat{y} = \sigma(\mathbf{W}^T \cdot \mathbf{z}^{(d)} + b) \quad (22)$$

其中, $\sigma(\cdot)$ 表示 Sigmoid 激活函数, \mathbf{W}^T 为预测层的线性变换系数, b 为偏置项; $\hat{y}; \hat{y} \in \{0, 1\}$ 为目标用户点击

某项目的预测得分。KAN-CTR 机制在这个预测过程中对高维特征空间中的复杂交互关系具备较强的表达能力,可显著提升 CTR 预测模型的精度与泛化能力。基于 KAN-CTR 机制的具体预测过程见算法 3。

算法 3 基于 KAN-CTR 机制的预测算法

输入:目标用户与目标项目的多跳簇级嵌入表示 $e_u^{(l)}, e_v^{(l)}(l=0, 1, 2)$,

KAN 网络层数 $D=3$,单个嵌入维度 h , B 样条基函数数量 $(g+r)$

输出:点击率预测得分 \hat{y}

Begin

1. 拼接多跳级嵌入表示为 e ; //见式(17)

2. 构造跳级交叉特征 S ; //见式(18)

3. 构建融合输入向量 x ; //见式(19)

/* KAN-CTR 网络的前向传播机制*/

4. For $d \leftarrow 0$ to $D-1$

5. For $i \leftarrow 1$ to $9h$ //对于每一维度进行变换

6. For $j \leftarrow 1$ to $g+r$

7. 计算第 j 个 B 样条基函数;

8. End For

9. 第 i 维输入的变换; //见式(21)

10. End For

11. 构造所有维度的非线性变换; //见式(20)

12. End For

13. Output 预测得分 \hat{y} ; //见式(22)

End

在算法 3 中,第 1~3 行融合目标用户与项目的不同层级兴趣与行为信息,并构造显式交叉特征用于建模跨跳间的交互语义。第 4~12 行是 KAN-CTR 网络的前向传播过程,对多层堆叠逐层提取高阶语义交互模式。第 13 行输出预测得分。

KAN-CTR 网络预测机制在每个维度上利用可学习的一元函数替代固定激活函数,融合用户与项目不同跳数下的语义表示与交叉特征,实现输入维度上较精细的变换,提升对多层交互结构的感知能力,在表达力与效率之间取得了良好平衡。至此, HCCF-KCTR 通过“结构层(结构重构)-语义层(簇级语义表征)-表达层(非线性交互)”的三层融合机制,完成从全局图结构层次化、局部簇特征提取到高阶非线性融合的全流程建模,形成结构驱动、语义感知且可解释的 CTR 预测框架。

为对模型中的可训练参数进行优化,本文采用点击率预测任务中广泛使用的二分类交叉熵损失函数作为监督学习目标,如式(23)所示。

$$\text{LogLoss} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1-y_i) \log(1-\hat{y}_i)] \quad (23)$$

其中, N 表示样本数, y_i 和 \hat{y}_i 分别表示真实值和估计值的点击概率。该损失函数直接衡量预测概率与真

实点击行为之间的偏差,能够有效指导模型学习更精确的概率输出。

在优化过程中,模型的所有可训练参数,包括混合社区层次化聚类后生成的嵌入表示、簇级邻居注意力权重参数以及 KAN-CTR 预测模块中的非线性函数参数,均通过反向传播机制在该监督损失的统一约束下进行联合更新。为避免过拟合并提升模型泛化能力,在训练阶段对嵌入层和预测层引入正则化项,最终优化目标如式(24)所示。

$$L = \text{LogLoss} + \lambda \|\theta\|_2^2 \quad (24)$$

其中, λ 为正则化系数, θ 表示模型的全部可训练参数集。

通过上述监督学习框架,所提模型 HCCF-KCTR 能够在结构感知和特征建模与高阶非线性交互表达之间实现稳定、高效的联合优化。

3 实验设计与分析

为阐明所提模型 HCCF-KCTR 的有效性及其优势,本文选择 4 个经典数据集进行综合实验对比与分析,主要回答下面几个问题。

RQ1:与经典的、较新的相关模型对比,本文模型有何优势效果如何?

针对此问题,3.4.1 节设置了对比实验,分别将本文模型与 13 种相关模型就性能方面在 4 个数据集上做对比,阐述本文模型的优势。

RQ2:本文模型的不同构件对模型自身的性能影响如何?是否有存在的必要性?

针对此问题,在 3.4.2 节设置了消融实验,由构件组成 4 种变体模型,分析不同构件对模型预测性能的影响。

RQ3:超参数如何影响本文模型的性能?

针对此问题,在第 3.4.3 节设置参数敏感度实验,分析主要超参数在不同数据集下对模型性能的影响,以进一步优化模型。

RQ4:模型的时间复杂度如何?

针对此问题,在第 3.4.4 节设置模型复杂度分析,计算本文模型的时间复杂度,并与主流模型比较,阐述本文模型复杂度情况。

RQ5:模型的效率如何?

针对此问题,在第 3.4.5 节设置模型效率分析,计算本文模型的运行效率与参数规模,并与主流模型比较,阐述本文模型效率情况。

3.1 数据集

本文选取 4 个较大规模公共数据集,它们均来自真实的业务场景,包括 MovieLens 数据集(<https://grouplens.org/datasets/movielens/10m/>)、Amazon 商品类数据

集(<http://jmcauley.ucsd.edu/data/amazon/>)中的 Electronics 数据集和 Book 数据集,以及 Taobao 数据集(<https://tianchi.aliyun.com/dataset/42>)。这 4 个数据集覆盖了电影娱乐、电子商务和在线搜索等多种交互场景,能较全面验证 CTR 模型在不同用户行为模式下的表现。它们均为近几年被大量学者使用和研究的经典数据集,数据质量良好,可比性强,便于与现有 CTR 方法进行公平对比,同时能验证本文方法在不同应用场景下的有效性和泛化能力,具体信息如表 2 所示。

表 2 数据集的数据统计表

Table 2 Data statistics of the dataset

数据集	用户	项目	类别	样本数
MovieLens	71 567	10 681	568 464	10 000 000
Electronics	192 403	63 001	801	1 689 188
Book	603 668	367 982	1 600	8 898 041
Taobao	987 994	4 162 024	9 439	100 150 807

(1) MovieLens: 广泛用于推荐系统研究的数据集,电影点评数据。数据标签包括用户与电影的基本特征、评分、ID 和电影类别等。

(2) Electronics: 广泛用于推荐系统研究的数据集。包含大量用户对电子类商品的评分、评论等信息,提供了丰富的上下文信息和隐性反馈数据。

(3) Book: Amazon-Book 数据集是推荐系统中常用的数据集之一,包含了用户和物品的交互信息。该数据集记录了用户对亚马逊网站上书籍的评价和相关信息。

(4) Taobao: 广泛用于许多 CTR 建模研究,该数据集由阿里巴巴集团提供,包含 2015 年 5 月—2015 年 11 月期间天猫电子商务平台上的用户行为历史。

3.2 评价指标

为验证模型 HCCF-KCTR 的预测性能是否有所提高,选取广泛使用的曲线下面积(Area Under Curve, AUC)、用户加权平均(Group AUC, GAUC)和对数损失(Logarithmic Loss, LogLoss)这 3 个评价指标对其性能进行评估。

(1) AUC 用于测量随机选择的正样本高于负样本的概率。该值越大,表明模型区分正负样本的能力越强,通常值越接近 1,模型的预测性能越好,如式(25)所示。

$$AUC = \frac{1}{n_{\text{pos}} \cdot n_{\text{neg}}} \sum_{i=1}^{n_{\text{pos}}} \sum_{j=1}^{n_{\text{neg}}} P(\hat{y}_{\text{pos}} > \hat{y}_{\text{neg}}) \quad (25)$$

其中, n_{pos} 和 n_{neg} 分别表示正、负样本数; \hat{y}_{pos} 和 \hat{y}_{neg} 分别为正、负样本的预测分数; $P(\cdot)$ 条件成立时为 1, 否则为 0。

(2) GAUC 用于更精细地衡量模型对每个用户个体的排序能力,是 AUC 在不同用户分组上的加权平均结果,GAUC 能更好地体现模型对个体用户的预测能力,如式(26)所示。

$$GAUC = \frac{\sum_{i=1}^{|U|} n_{u_i} \cdot AUC_{u_i}}{\sum_{i=1}^{|U|} n_{u_i}} \quad (26)$$

其中, $|U|$ 表示用户数, AUC_{u_i} 是用户 u_i 的 AUC 值, n_{u_i} 是 u_i 的样本数(即该用户的点击与未点击样本总数)。

(3) LogLoss 用于评估模型的预测概率和真实点击之间的误差,是预测任务中评估概率预测质量的常用指标。其值越小,表示模型的预测概率越接近真实点击概率,如式(23)所示。

3.3 对比模型

本节将所提模型 HCCF-KCTR 与经典的、先进的 13 种相关模型进行比较,包括 5 种特征交互模型、4 种用户兴趣模型以及 4 种基于图的模型。

特征交互模型:关注如何建模输入特征之间的交叉组合关系,从而捕捉用户与项目之间的潜在交互模式。

(1) AutoInt^[31] 引入多头自注意力机制,在嵌入空间中显式建模高阶特征交互,是基于 Transformer 架构的代表性 CTR 预测模型。

(2) xDeepFM^[11] 是高级特征交叉建模的代表,融合 FM 模型的显式特征交互建模与 DNN 的非线性特征表达,并引入压缩交叉网络(CIN),高效地建模特征组合。

(3) KAN^[15] 采用可学习的一元 B 样条基函数作为非线性映射单元,通过维度独立建模与多层组合,实现对高阶非线性交互的高效表达,兼具结构灵活性与表达力,与本文模型的 KAN-CTR 预测机制结构一致。

(4) TWIN^[40] 结合通道分离与特征交叉显式建模用户项目间的语义关系,与本文模型多层次信息聚合相关联。

(5) IPA^[41] 采用一种通用的统一框架,通过交互函数、层池化以及层聚合器三个部分,将所有层的输出结合起来,作为后续精准分类器的输入。

用户兴趣模型:关注用户兴趣的动态变化与行为子序列的建模,适用于处理序列化点击或上下文行为序列。

(6) LREA^[42] 使用低秩矩阵分解与矩阵吸收机制,整合长期行为特征,提升长期兴趣表示的压缩性与稳定性。

(7) DIEN^[10] 引入注意力更新门(Attention Update GRU, AUGRU),对历史行为中的兴趣演化进行动态建模,使模型能更准确地挖掘与当前目标项目相关的兴趣。

(8) SIM^[43] 采用两阶段兴趣检索机制,第一阶段使用 GSU 快速粗筛,第二阶段利用 ESU 精细捕捉子行为与目标项目之间的语义关系,从而精确表达用户的真实兴趣。

(9) MIRR^[44]是最新研究聚焦于用户长期兴趣的多粒度检索与精炼建模的模型,通过多时间尺度查询检索多粒度兴趣子序列,引入多头傅里叶变换器高效建模序列关系与交互,并结合多头注意力机制,自适应评估各粒度兴趣对目标物品的影响。

基于图的模型:将用户与项目之间的交互行为建模为图结构,通过GNN等机制捕捉结构信息与邻居传播特性。

(10) NGCF^[5]是图神经推荐的代表性方法,利用GCN在用户-项目图上进行特征传播,整合多跳邻居信息来增强用户与项目的嵌入表示,具备较强的结构表达能力。

(11) LightGCN^[3]是NGCF的简化版本,移除了非线性激活函数与特征变换矩阵,仅保留必要的邻居聚合操作,在提升模型计算效率同时保留性能。

(12) NRCGI^[39]引入图聚类思想,强调簇结构在用户-项目建模中的作用,与本文模型的簇级提取模块有关联。

(13) KarSein^[37]是首个基于KAN架构的CTR预测模型,通过引入成对乘法操作,强制网络学习乘法关系,从而更好地捕提高阶特征交互,与本文模型的KAN-CTR预测结构相关。

3.4 实验及其分析

在实验中,对于各个模型的公共超参数均采用相

同值且基于PyTorch实现,并使用Adam优化器进行训练。对于基线模型中的特定超参数,我们使用原始参考模型中的值。对于本文模型HCCF-KCTR,默认学习率设为0.1,在验证性能连续3个epoch无提升时,将学习率按比例缩小10倍。对所有模型,每个实验运行5次,并在验证集中选择最佳结果。

下面结合3种综合实验阐述本文模型的有效性及其优势。其中,对比实验(见3.4.1节)将本文模型与13种经典的、较新的推荐模型进行对比,为保证实验的公平性,各模型选取各自所需较为合理的数据集划分比例,阐明本文模型的优势,以回答RQ1;消融实验(见3.4.2节)阐述本文模型的相关构件对模型推荐性能提高的可行性与高效性,以回答RQ2;参数敏感度实验(见3.4.3节)分析主要参数对模型性能方面的影响,便于实施模型参数优化,以回答RQ3;复杂度分析(见3.4.4节)主要阐述本文模型复杂度情况,以回答RQ4;效率分析(见3.4.5节)阐明本文模型的运行效率与参数规模情况,以回答RQ5。

3.4.1 对比结果与分析(RQ1)

表3给出了本文模型HCCF-KCTR与13种对比模型在4个公开数据集上的性能表现。为便于比较,利用虚线区分特征交互模型、用户兴趣模型和基于图的模型3种不同类型的对比模型。

表3 各模型性能比较

Table 3 Performance comparison of each model

模型	MovieLens			Electronics			Book			Taobao		
	AUC	GAUC	LogLoss	AUC	GAUC	LogLoss	AUC	GAUC	LogLoss	AUC	GAUC	LogLoss
AutoInt	0.681 3	0.692 5	0.607 4	0.788 6	0.786 4	0.557 5	0.798 7	0.756 9	0.547 8	0.803 5	0.824 3	0.529 8
xDeepFM	0.678 6	0.679 2	0.642 1	0.770 3	0.772 5	0.559 6	0.732 1	0.728 9	0.563 4	0.814 9	0.811 1	0.535 9
KAN	0.776 7	0.788 5	0.571 4	0.826 7	0.826 7	0.532 2	0.852 1	0.862 4	0.445 7	0.803 9	0.798 2	0.542 2
TWIN	0.786 4	0.792 4	0.574 1	0.843 2	0.845 5	0.498 9	<u>0.897 6</u>	0.892 3	0.429 1	<u>0.894 5</u>	0.892 4	0.482 4
IPA	0.802 9	0.787 8	0.567 3	<u>0.851 5</u>	0.842 3	0.499 1	0.872 6	0.894 7	0.443 2	0.884 3	0.865 2	<u>0.480 9</u>
LREA	0.799 8	0.791 9	0.586 2	0.848 9	<u>0.847 8</u>	0.501 2	0.887 8	0.890 5	0.432 2	0.879 8	0.878 8	0.488 2
DIEN	0.736 9	0.723 5	0.612 7	0.816 9	0.802 1	0.548 9	0.804 6	0.817 5	0.512 4	0.818 8	0.821 3	0.531 3
SIM	0.730 5	0.719 6	0.620 3	<u>0.819 8</u>	0.817 6	0.520 8	0.848 6	0.822 1	0.513 6	0.854 6	0.861 1	0.503 9
MIRRN	0.802 5	<u>0.796 9</u>	<u>0.566 8</u>	0.847 7	0.831 7	0.495 3	0.889 8	0.891 7	<u>0.418 4</u>	0.892 9	0.875 4	0.485 8
NGCF	0.701 5	0.699 8	0.659 7	0.812 2	0.810 9	0.526 5	0.867 4	0.850 1	0.508 8	0.867 7	0.870 3	0.498 1
LightGCN	0.701 1	0.710 2	0.634 1	0.818 6	0.836 5	0.518 2	0.871 5	0.861 0	0.458 1	0.851 2	0.856 2	0.510 4
NRCGI	0.748 6	0.740 7	0.590 7	0.838 6	0.838 9	0.494 5	0.891 7	<u>0.898 6</u>	0.419 5	0.879 8	0.884 8	0.493 4
KarSein	0.793 3	0.793 8	0.572 1	0.845 7	0.846 1	<u>0.494 1</u>	0.889 1	0.890 7	0.420 5	0.882 4	<u>0.897 3</u>	0.487 8
HCCF-KCTR	0.812 5	0.804 5	0.554 6	0.866 8	0.860 7	0.480 8	0.930 4	0.935 8	0.392 7	0.928 7	0.921 1	0.462 9
性能提升/%	1.190 0	0.950 0	2.150 0	1.790 0	1.520 0	2.690 0	4.160 0	3.650 0	6.140 0	3.820 0	2.650 0	3.740 0

注:本文模型HCCF-KCTR的实验数据以加粗字体标示,为便于比较,利用下划线来突显变体模型中表现最佳的数据,最后一行给出模型相对于某一最佳变体模型的性能提升情况(粗体标示)。

所有模型在MovieLens, Electronics, Book及Taobao数据集上的实验结果见表3。其中,本文模型

HCCF-KCTR在各数据集上整体表现良好,在AUC, GAUC及LogLoss这3个评价指标上相较对比模型均

有所提升,下面给出更详细的分析。

(1)与特征交互模型对比

传统特征交互模型 xDeepFM 与 AutoInt 分别通过压缩交叉网络和多头自注意力机制建模高阶特征关系,在一定程度上增强了特征表达能力。其中,AutoInt 模型通过 Transformer 架构显式学习任意阶特征交互,相较于固定内积式建模方式具有更强的交互灵活性。但这类模型的交互结构相对固定,在高维稀疏特征场景下易产生过拟合现象,其在 4 个数据集上的整体性能均未占优。

相比之下,KAN 模型通过可学习的非线性函数对各维输入特征进行结构化映射,在高阶特征交互建模方面展现出更强的灵活性与表达能力,整体性能在多个数据集上的表现优于 AutoInt 与 xDeepFM,这验证了函数分解式建模在高阶交互表达中的有效性。

在此基础上,IPA 模型通过统一的特征交互框架进一步增强了交互表达能力,性能略优于 KAN,在 4 个数据集中 AUC、GAUC 及 LogLoss 指标均取得了更优的表现,这表明全连接式特征交互有助于捕捉更广泛的特征关联。

TWIN 模型采用双通道结构对用户与项目特征进行显式建模,在多数数据集上取得该组中最优结果,显示了其在特征交互表达上的优势。例如在 4 个数据集中,AUC、GAUC 及 LogLoss 指标分别平均提升 7.43%、7.65% 和 7.98%,这主要得益于 TWIN 能在不同特征空间中分别建模交互模式,从而有效缓解单一交互路径带来的表达受限问题。

相较于上述特征交互模型,所提模型 HCCF-KCTR 在所有数据集及评价指标上均取得更优的性能。与特征交互模型中表现最佳的 TWIN 相比,HCCF-KCTR 在 AUC、GAUC 及 LogLoss 指标上分别至少提升 2.79%、1.53% 和 3.39%。其原因在于,HCCF-KCTR 并非仅依赖显式或隐式特征交叉,而是通过混合社区层次化建模引入结构先验信息,并结合簇级多跳语义聚合与 KAN 的高阶非线性交互能力,实现结构信息与特征交互的深度融合,以显著增强模型整体表达能力与预测性能。

总体而言,现有特征交互模型虽通过显式或压缩方式模拟特征之间高阶交互,具备良好的交互建模基础,但多数局限于固定结构和浅层表达。相比之下,HCCF-KCTR 模型引入灵活可学习的 KAN 交互机制,在避免深层 MLP 所带来的训练不稳定与解释困难的同时,提升了其表达能力与推理效率,展现出更强的性能优势。

(2)与用户兴趣模型对比

用户兴趣建模类通常通过对用户历史行为进行

序列化建模,以刻画用户兴趣的动态演化过程。其中,DIEN 模型将注意力机制引入 GRU 单元来捕捉兴趣随时间的变化,在短期行为建模方面具有一定优势。然而,该模型主要依赖序列顺序关系,缺乏对用户-项目之间结构关联的刻画,在复杂交互场景下其性能提升受到限制,在 4 个数据集上的整体表现相对较弱。

SIM 模型在 DIEN 的基础上引入两阶段检索机制,通过行为筛选提升关键行为建模的有效性,其性能整体优于 DIEN,说明对用户历史行为进行选择性地建模有助于减少噪声干扰。LREA 模型进一步通过低秩约束对长期兴趣进行建模,在稳定性和鲁棒性方面表现更优,并在多个数据集上取得高于 SIM 的 AUC 与 GAUC 指标。

在此基础上,MIRRN 模型通过多粒度兴趣检索与精炼机制对长期行为进行细粒度建模,在兴趣动态刻画方面获得更优表现,其在 4 个数据集上的预测性能更优。例如在 4 个数据集中,AUC、GAUC 及 LogLoss 指标分别平均提升 5.28%、4.09% 和 7.55%,这表明多粒度建模机制能更充分地挖掘用户行为蕴含的潜在兴趣信息。

相较于上述用户兴趣模型,所提模型 HCCF-KCTR 在所有数据集及评价指标上均取得了更优的性能。与该类模型中表现最好的 MIRRN 相比,所提模型 HCCF-KCTR 模型在 AUC、GAUC 及 LogLoss 指标上平均提升 2.40%、3.65% 和 3.98%。其原因在于,所提模型 HCCF-KCTR 在多粒度建模基础上,同时引入簇级邻居特征提取机制,在结构先验信息指导下进行多跳聚合,实现对用户-项目跨簇关系的动态建模。

总体而言,现有基于用户兴趣的模型多聚焦于行为选择与序列建模,缺乏图结构支持与高阶交互表达。相比之下,HCCF-KCTR 模型不仅考虑节点之间的静态属性,还通过层次化聚类与簇级邻居机制动态聚合结构相似节点的多跳用户,有效地挖掘潜在兴趣关系的结构化建模,从而更精细地捕捉复杂的兴趣交互模式。

(3)与基于图的模型对比

基于图的 CTR 预测模型通过在用户-项目交互图上进行多跳信息传播,显式建模节点之间的结构关系,在刻画复杂交互依赖方面具有优势。其中,NGCF 模型通过引入 GCN 框架对高阶邻居信息进行传播,能够有效捕捉多跳结构依赖关系。然而,随着传播层数的增加,噪声信息不断累积,使其在深层建模场景下易出现性能退化。LightGCN 模型在此基础上移除非线性变换与权重矩阵,仅保留核心邻域聚合操作,在计算效率方面取得明显优势,其整体性能优于 NGCF。这表明在稀疏推荐场景下适当控制模型复杂度有助于结构信息传播。

NRCGI 模型进一步引入图聚类机制对用户与项

目进行结构重组,在增强嵌入结构一致性的同时缓解噪声传播,其预测性能整体优于 LightGCN。KarSein 模型在此基础上结合成对乘法机制以增强高阶交互建模能力,并通过精简计算结构提升模型效率,在多组数据集上取得该类模型中的最优性能,AUC、GAUC 及 LogLoss 指标上分别平均提升 4.16%、4.57% 和 6.05%,这表明,在图结构建模的基础上结合显式非线性交互机制能够有效提升 CTR 预测性能。

相较于上述基于图的模型,所提模型 HCCF-KCTR 在所有数据集及评价指标上均取得了更优的性能。与基于图的对比模型中表现最优的 KarSein 模型相比,HCCF-KCTR 在 AUC、GAUC 及 LogLoss 指标上进一步取得显著提升,分别至少提升 2.42%、1.35% 和 2.69%,这主要得益于 HCCF-KCTR 通过混合社区层次化聚类对原始交互图进行结构压缩与分层重构,在减少噪声传播的同时保留关键结构信息,并结合簇级邻居特征提取机制实现多跳语义增强,最终借助 KAN-CTR 非线性交互模块对结构化簇表示进行高阶融合,从而在结构建模深度与表达能力之间取得更优平衡。

总体而言,现有基于图的 CTR 模型通过多跳信息传播建模用户与项目间的交互关系,展现出良好的结构学习能力,但预测效果易受图稀疏性与高阶建模表达不佳影响。相比之下,本文模型 HCCF-KCTR 通过混合层次聚类模块压缩结构冗余,并引入结构感知建模机制与基于 KAN 机制的非线性交互建模模块,在表达能力与结构适应性之间取得良好的平衡,从而有效缓解图结构稀疏与高阶交互建模困难的问题。

综上所述,相比于其他模型,所提模型 HCCF-KCTR 在 MovieLens、Electronics、Book 及 Taobao 这 4 个数据集上的性能均有明显提升。(a)从数据集维度来看,HCCF-KCTR 在 Book 数据集上的表现尤为突出,平均提升达 13.38%。因 Book 数据集中图书类物品具有较高的主题连贯性,用户偏好相对稳定,结构聚类特征明显,而 HCCF-KCTR 构建的多跳簇级感知机制在结构清晰、兴趣集中型场景下具有较强的表达与建模能力。在 Electronics 与 Taobao 数据集上,模型分别平均提升 6.46% 和 8.77%,表现也较为优秀,验证了模型在大规模电商场景中的泛化能力。而在 MovieLens 数据集上,尽管表现略逊一筹,但仍取得平均 3.66% 的提升,说明模型在处理多样性高、用户兴趣变化较大的场景下稳定性也较强。(b)从指标维度来看,HCCF-KCTR 在 AUC、GAUC 及 LogLoss 分别平均提升 9.22%、8.65% 和 10.76%。这一结果表明,融合混合社区与簇级特征的 KAN-CTR 预测框架不仅提升了 CTR 预测任务中的排序准确率,也验证了模型融合表达机制的有效性。总之,本文模型 HCCF-KCTR 引入混合社区层次化聚类策略增强结构划分能力,利用簇级邻居特征

提取模块建模多跳结构语义,结合基于 KAN 的非线性交互建模机制实现深度表达与高效预测,在不同场景下均展现出良好的性能与泛化能力。

3.4.2 消融实验分析(RQ2)

(1)模型构件对预测性能的影响

为验证混合社区层次聚类策略、簇级特征提取模块以及 KAN-CTR 预测机制这三个构件对点击率预测性能的影响,设计了 4 种变体模型,将它们与本文模型 HCCF-KCTR 进行对比,以证明各构件存在的必要性。其中,(a)Ours-1 仅保留混合社区的层次聚类策略,不引入簇级特征提取模块,也不使用基于 KAN-CTR 预测机制捕获高阶特征。将该变体模型用于对比,主要评估混合社区层次化聚类策略对全局交互关系建模的影响。(b)Ours-2 仅引入 KAN-CTR 预测机制,不使用层次化聚类策略与簇级邻居特征提取模块。该变体模型主要反映 KAN-CTR 预测机制对非线性特征建模的贡献。(c)Ours-3 结合层次化聚类策略与簇级邻居特征提取模块,不使用 KAN-CTR 预测机制。将该变体模型用于对比,主要反映混合社区层次化聚类策略与簇级特征提取模块的协同效果,同时考察 KAN-CTR 机制对非线性特征建模的影响。(d)Ours-4 结合层次化聚类策略与 KAN-CTR 预测机制,不采用簇级邻居特征提取模块。将该变体模型用于对比,主要阐述混合社区层次化聚类策略与 KAN-CTR 预测机制组合的有效性,同时考察簇级邻居特征提取模块对预测性能的影响。需说明的是,对仅使用簇级邻居特征提取模块的变体,及结合簇级邻居特征提取模块和 KAN-CTR 预测机制的变体,这两种情况无需讨论,因为簇级邻居特征提取模块需依靠层次化聚类策略获得精确的社区划分;三个构件均不使用的变体模型因效果不如其他模型,故无需讨论。各模型的构件描述情况如表 4 所示。

表 4 各模型的构件描述情况

Table 4 Component description of each model

变体模型	混合社区层次化聚类策略	簇级邻居特征提取模块	KAN-CTR 预测机制
Ours-1	√	×	×
Ours-2	×	×	√
Ours-3	√	√	×
Ours-4	√	×	√
HCCF-KCTR	√	√	√

注:“×”为变体模型中剔除该组件,“√”为包含该组件。

在 MovieLens、Electronics、Book 及 Taobao 这 4 组公开数据集进行消融实验,考虑到变体模型的目的是验证各构件对预测性能的影响,这里选择 AUC、GAUC 及 LogLoss 作为评价指标。实验结果如表 5 所示。

表 5 各构件对模型性能的影响

Table 5 Impact of each component on model performance

数据集	评价指标	各模型					最少提升/%
		Ours-1	Ours-2	Ours-3	Ours-4	HCCF-KCTR	
MovieLens	AUC	0.770 9	0.782 8	0.781 2	<u>0.791 1</u>	0.812 5	2.71
	GAUC	0.780 2	0.769 6	0.790 7	<u>0.791 6</u>	0.804 5	1.63
	LogLoss	0.598 3	0.577 9	0.592 6	<u>0.569 2</u>	0.554 6	2.57
Electronics	AUC	0.805 3	0.839 5	0.831 2	<u>0.845 1</u>	0.866 8	2.57
	GAUC	0.797 2	0.820 4	<u>0.843 5</u>	0.822 8	0.860 7	2.04
	LogLoss	0.512 1	0.510 6	0.514 4	<u>0.507 3</u>	0.480 8	5.22
Book	AUC	0.890 4	0.886 8	0.902 9	<u>0.914 3</u>	0.930 4	1.76
	GAUC	0.865 6	0.875 3	0.896 8	<u>0.901 2</u>	0.935 8	3.84
	LogLoss	0.457 5	0.441 3	0.436 6	<u>0.429 2</u>	0.392 7	7.34
Taobao	AUC	0.886 2	0.905 6	0.874 2	<u>0.910 3</u>	0.928 7	2.02
	GAUC	0.854 7	0.894 6	0.875 2	<u>0.927 9</u>	0.921 1	0.73
	LogLoss	0.518 2	0.497 7	<u>0.488 1</u>	0.492 4	0.462 9	5.99

注:本文模型 HCCF-KCTR 的实验数据以加粗字体标示,为便于比较,利用下划线来突显变体模型中表现最佳的数据,最后一列给出所提模型相对于某一最佳变体模型的性能提升情况(粗体标示)。

从表 5 可看出, KAN-CTR 预测机制对模型性能影响最大,与仅使用混合社区层次化聚类策略的变体模型 Ours-1 相比,引入 KAN-CTR 预测机制的变体模型 Ours-4 的效果有明显提升;混合社区层次化聚类策略对模型性能有较大影响,使用 KAN-CTR 预测机制的变体模型 Ours-2 在 AUC、GAUC 及 LogLoss 这 3 个指标上的表现,均不如在其基础上引入了层次化聚类策略的变体模型 Ours-4,簇级邻居特征提取模块对模型性能有一定影响,仅使用层次化聚类策略的变体模型 Ours-1 和结合该策略与 KAN-CTR 预测机制的变体模型 Ours-4 在 AUC、GAUC 及 LogLoss 这 3 个指标上的表现,均分别不如在它们基础上引入簇级邻居特征提取模块的变体模型 Ours-3 和本文模型。下面给出更详细的分析。

(a)从仅保留混合社区层次化聚类策略的变体模型(Ours-1)来看,层次化聚类策略与其他构件的组合具有合理性。本文模型 HCCF-KCTR 利用混合社区层次化聚类策略,对用户和项目节点进行结构化划分,获得初步的簇结构,需进一步结合上下文信息和语义感知机制进行增强。而簇级邻居特征提取模块和 KAN-CTR 预测机制可在此基础上充分挖掘多跳结构信息并建模复杂的交互关系。与 Ours-1 相比,所提模型 HCCF-KCTR 有较大提升,在 AUC、GAUC 及 LogLoss 指标上分别平均提升 5.58%、6.74% 以及 9.29%。其中,在 LogLoss 指标上,至少提升 6.11%,最多提升可达 13.07%。此外,Ours-3 和 Ours-4 变体模型在引入其他组件后性能亦有明显改善。由此可知,混合社区层次化聚类策略与其他模块之间存在互补性。

(b)从仅保留 KAN-CTR 预测的变体模型(Ours-2)来看,KAN-CTR 预测机制与其他构件的组合是有效的。本文模型 HCCF-KCTR 引入的 KAN-CTR 预测机制基于可学习 B 样条函数的 KAN 网络,用于建模高阶非线性交互关系,显著增强模型对复杂特征组合的表达能。然而,若缺乏结构化先验信息输入,如聚类或簇划分结果,则预测模块难以准确建模节点之间的结构语义关系。我们通过引入混合社区层次化聚类策略,模型可获得清晰的结构划分,同时结合簇级注意力机制,提取目标节点的簇感知多跳表示,从而提升邻居的多跳簇级表示的一致性与结构表达能力。与 Ours-2 相比,所提模型 HCCF-KCTR 性能有较大提升,在 AUC、GAUC 和 LogLoss 指标上分别平均提升 3.62%、4.83% 和 8.47%。其中,在 LogLoss 指标上至少提升 4.03%,最多提升可达 9.88%。此外,Ours-4 在 Ours-2 的基础加入聚类模块后性能亦明显提升,表明 KAN-CTR 预测机制与其他两个组件的协同建模的有效性。

(c)从仅结合混合社区层次化聚类策略和簇级邻居特征提取模块的变体模型(Ours-3)来看,KAN-CTR 预测机制对模型性能的平均影响很大。该变体模型通过构建多粒度簇结构提取多跳簇感知特征,获得目标节点的簇感知多跳表示,但若仍依赖传统高阶建模方法,难以充分捕捉高阶非线性交互,限制了模型的最终预测精准度。引入的 KAN-CTR 预测机制可有效提高模型的高阶表达能力。与 Ours-3 相比,所提模型 HCCF-KCTR 性能有明显提升,在 AUC、GAUC 和 LogLoss 指标上分别平均提升 4.39%、3.35% 和 6.75%。其中,在 LogLoss 指标上至少提升 5.16%,最多提升可达

8.91%。这表明, KAN-CTR 预测机制是模型性能显著跃升的关键组件, 对整体推荐效果的优化有重要作用。

(d) 从仅结合混合社区层次化聚类策略和 KAN-CTR 预测机制的变体模型(Ours-4)相比, 簇级邻居特征提取模块对模型性能的影响明显。本文模型 HCCF-KCTR 基于簇划分结果, 引入簇感知注意力机制进行多跳邻居聚合, 能够自适应建模邻居节点对目标节点的语义相关性与结构重要性, 从而突出关键交互行为, 缓解信息冗余问题。与 Ours-4 相比, 所提模型 HCCF-KCTR 性能略有提升, 在 AUC、GAUC 和 LogLoss 指标上分别平均提升 2.27%、2.70% 和 5.28%。其中, 在 LogLoss 指标上至少提升 2.57%, 最多提升可达 7.34%。这进一步验证了簇级邻居特征提取模块在捕捉跨跳簇结构语义关系方面的影响, 能够补充聚类结构的细粒度信息, 从而提升嵌入表达的上下文语义一致性。

综上分析, 所提模型 HCCF-KCTR 的各个组件对提升其性能均有一定程度上的作用。①混合社区层次化聚类策略与其他构件的组合是合理的, 能有效处

理全局复杂交互, 与簇级邻居特征提取模块和 KAN-CTR 预测机制共同作用, 显著提升了模型性能。②簇级邻居特征提取模块通过簇级感知映射与注意力池化, 实现对不同跳数邻居嵌入的层次化建模, 与混合社区层次化聚类策略的簇划分结果有效结合, 对模型性能具有积极作用。③KAN-CTR 预测机制利用自适应激活函数结构, 与层次化聚类策略和簇级邻居建模模块协同作用, 能充分挖掘高阶非线性交互特征, 显著提升了预测准确度。

(2) 簇感知注意力池化机制对模型预测性能的影响

对于所提模型 HCCF-KCTR 的簇级邻居特征提取模块, 我们进一步对该模块中的注意力池化机制进行消融实验, 分析注意力池化对模型预测性能的影响。具体而言, 在保持其余模块不变的前提下, 将原有的簇感知注意力池化分别退化为普通邻居级加权聚合、平均池化, 并在 MovieLens、Electronics、Book 与 Taobao 四个数据集上, 对最终预测性能做对比。实验结果如表 6 所示。

表 6 簇感知注意力池化机制对模型性能的影响

Table 6 Impact of cluster-aware attention pooling mechanism on model performance

数据集	评价指标	对比机制			最少提升/%
		普通邻居加权	平均池化	注意力池化	
MovieLens	AUC	0.793 7	<u>0.803 2</u>	0.812 5	1.16
	GAUC	0.788 1	<u>0.797 6</u>	0.804 5	0.87
	LogLoss	0.572 0	<u>0.562 4</u>	0.554 6	1.39
Electronics	AUC	0.851 2	<u>0.860 7</u>	0.866 8	0.70
	GAUC	<u>0.854 9</u>	0.843 5	0.860 7	0.68
	LogLoss	0.503 2	<u>0.488 3</u>	0.480 8	1.54
Book	AUC	<u>0.905 6</u>	0.901 7	0.930 4	2.73
	GAUC	0.889 4	<u>0.910 5</u>	0.935 8	2.78
	LogLoss	0.441 9	<u>0.400 3</u>	0.392 7	1.89
Taobao	AUC	0.896 1	<u>0.914 2</u>	0.928 7	1.59
	GAUC	0.914 5	<u>0.903 6</u>	0.921 1	1.94
	LogLoss	0.498 7	<u>0.473 9</u>	0.462 9	2.32

注: 注意力池化机制为所提模型 HCCF-KCTR 使用, 其实验数据以加粗字体标示。为便于比较, 利用下划线来突显另外 2 种机制(普通邻居加权与平均池化)中表现最佳的数据, 最后一列给出所提模型相对于这 2 种机制中最佳性能的提升情况(粗体标示)。

由表 6 可知, 相比简单的加权聚合与平均池化情形, 所提模型 HCCF-KCTR 在引入簇感知注意力池化后, 在 AUC、GAUC 及 LogLoss 指标上分别最少平均提升 1.54%、1.57% 以及 1.78%。其中, 在 LogLoss 指标上, 至少提升 1.39%, 最多提升可达 2.32%。这一结果表明, 简单的加权聚合与平均池化难以有效区分不同邻居在多跳传播中的语义贡献, 易引入冗余与噪声信息。而簇感知注意力池化机制能充分利用混合社区层次化聚类所形成的簇结构信息, 其通过簇内与簇间两级注意力建模, 先在簇内突出高贡献邻居节点, 再在簇间自适应分配不同簇的影响权重, 从而实现

对簇结构中异质信息传播的精细化建模。该机制能增强关键结构语义的表达能力, 也可有效抑制低相关或噪声邻居对目标表示的干扰。

综上, 簇感知注意力池化机制是所提模型的簇级特征提取模块中提升结构语义表达能力与预测性能的重要部分, 其在区分关键邻居与噪声邻居、稳定多跳表示学习方面发挥了积极作用。

3.4.3 参数敏感度分析(RQ3)

(1) 细粒度子簇数 k 的影响

Louvain 算法和谱聚类过程中, 簇划分的子簇数 k

影响了簇级邻居关系的表达粒度。过小的 k 导致簇内用户和物品的多样性过高,影响特征提取效果;过大的 k 会增强数据稀疏性,削弱簇间信息的可聚合性。关于 k 的值,设

置其取值来源于集合 $\{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12\}$,通过实验选取较优的值。不同数据集下 AUC、GAUC 和 LogLoss 指标值随 k 变化的情况如图2所示。

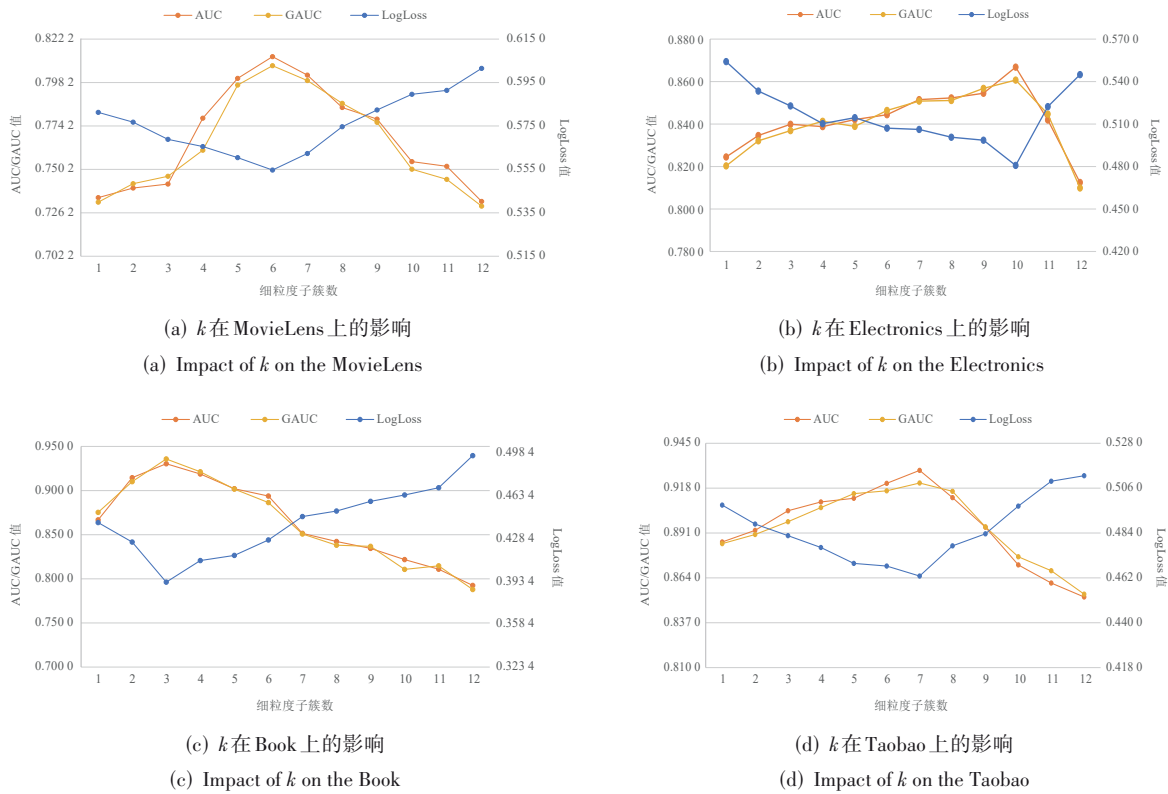


图2 细粒度子簇数 k 的影响

Figure 2 Impact of the number of fine-grained subclusters k

由图2可知,当谱聚类中的子簇数 $k=1$ 时,即在混合社区层次化聚类模块中未进一步划分细粒度,仅保留粗粒度划分。在 MovieLens、Electronics、Book 及 Taobao 这4个数据集上,模型的 AUC、GAUC 指标均处于较低水平,LogLoss 值则相对较高,这表明过小的簇数无法捕捉簇内丰富的结构变化,导致特征融合能力不足;随着 k 增大,不同数据集在不同子簇数下表现最优:Book 数据集在 $k=3$ 、MovieLens 在 $k=6$ 、Taobao 在 $k=7$ 、Electronics 在 $k=10$ 时效果最佳。这一结果说明,最优子簇数并非统一,而是受制于数据集内部的交互密度与结构特性。例如,Book 数据集中图书类数据通常具有较强的主题连贯性,用户阅读偏好分布集中,较小粒度的划分($k=3$)可较好地维持每个簇内的密度和样本规模,避免子簇划分过细而引发稀疏问题,同时保持合理的兴趣聚类表达;MovieLens 数据集中用户的兴趣多样性较强,且电影种类丰富,设置 $k=6$ 可更细致地区分这些兴趣群体,增强簇内结构表达的能力,有助于学习更精细的簇级邻居特征并提升高阶交互建模质量;Taobao 数据集是大规模点击率预测数

据集,用户行为碎片化,数据高度稀疏,中等粒度的划分($k=7$)有助于缓解因过细聚类带来的过拟合风险,同时保证每个子簇内仍有足够的样本支撑语义建模,有效提升表达稳定性;Electronics 数据集中电子产品品类极多、更新频繁,用户购买行为更复杂且个性差异更大,较大粒度的划分($k=10$)更适合提取设备之间细微结构差异,提高模型对异质邻居的表达能力,优化语义对齐与跨跳交互效果。

可见,不同数据集的最优 k 值会受其结构特性影响,选择合适的细粒度子簇数能更准确地捕捉局部结构特征,增强簇级建模效果,对增强模型的结构表达与预测能力具有重要意义。

(2) KAN 网络层数 D 的影响

CTR-KAN 预测模块中的网络层数 D 决定了模型在特征融合阶段对非线性交互关系的建模能力。其通过 Kolmogorov-Arnold 分解,将高维特征映射为多个单变量函数组合,以此避免 MLP 在深层结构中常见的梯度消失和冗余建模问题,设置其值在集合 $\{1, 2, 3, 4\}$ 中选取。将 AUC、GAUC 及 LogLoss 作为评价指

标,验证 D 的不同取值对推荐效果的影响,针对 4 个数据集中的不同传播层的实验结果如图 3 所示。

由图 3 可看出,当 KAN 网络层数 $D=1$ 时,在 MovieLens、Electronics、Book 这 3 个数据集上,AUC 与 GAUC 指标值均普遍较低,LogLoss 则相对较高;而在 Taobao 数据集中,性能最低点出现在 $D=2$ 时。这表明在浅层结构下,KAN 模块难以充分捕捉多跳簇结构中的复杂特征交互,导致模型表达能力受限、性能表现不佳。随着 D 的不断增大,模型的非线性建模能力逐步增强,预测性能逐渐提升。当 $D=3$ 时,模型在各数据集性能均达到最佳,此时网络深度能较好地权衡建模能力与训练稳定性,既具备足够的非线性交互表达能力,又未引入过多冗余计算。随着 D 继续增大,模型性能又呈下降趋势,这是由于过深的结构(如 $D=4$)会导致参数过多,模型过拟合风险增加,同时可能引发梯度消散与训练稳定性问题,反而使预测性能下降。可见,通过合理设置网络层数 D ,可有效优化模型的特征交互建模能力与预测性能。考虑到整体实验表现,本文将 KAN 模块的网络层数 D 设置为 3。

3.4.4 模型复杂度分析(RQ4)

所提模型 HCCF-KCTR 利用混合社区层次化聚类策略、簇级邻居特征提取模块和 KAN-CTR 预测机制

实现 CTR 预测任务,与现有相关模型相比,预测过程稍长,尽管复杂度相对有所增加,但模型的推荐效果得到较大提升。下面对本文模型及部分具有代表性的对比模型就其时间复杂度进行分析。

(1) 本文模型 HCCF-KCTR 的时间复杂度主要来源于混合社区的层次化聚类与 KAN-CTR 预测两个核心模块。混合社区的层次化聚类模块通过 Louvain 算法进行全局划分,结合谱聚类实现局部优化,时间复杂度约为 $O(NM \log N + k^3)$,其中 N 为用户和物品总数, M 为平均邻居数, k 为最终簇数;簇级特征提取模块需对 1 跳和 2 跳邻居进行采样与注意力加权,复杂度约为 $O(Nd^2)$,其中 d 表示节点的平均度数;在模型预测模块中,引入了 KAN 对高维输入执行非线性映射,其复杂度约为 $h(d+hD)(g+r)$,其中 h 为每层神经元数, D 为 KAN 变换层数, g 表示节点间的间隔数, $(g+r)$ 为 B 样条基函数数量(每个阶数为 r)。因此,HCCF-KCTR 总时间复杂度可表示为 $O(NM \log N + k^3 + Nd^2 + h^2(D(g+r)))$ 。

(2) 就对比模型 AutoInt(基于 Transformer 架构的 CTR 预测代表性模型)的时间复杂度来说,其时间主要消耗在显式交互特征构造阶段,时间复杂度大致为 $O(hn^2d)$,其中 n 为特征数量。

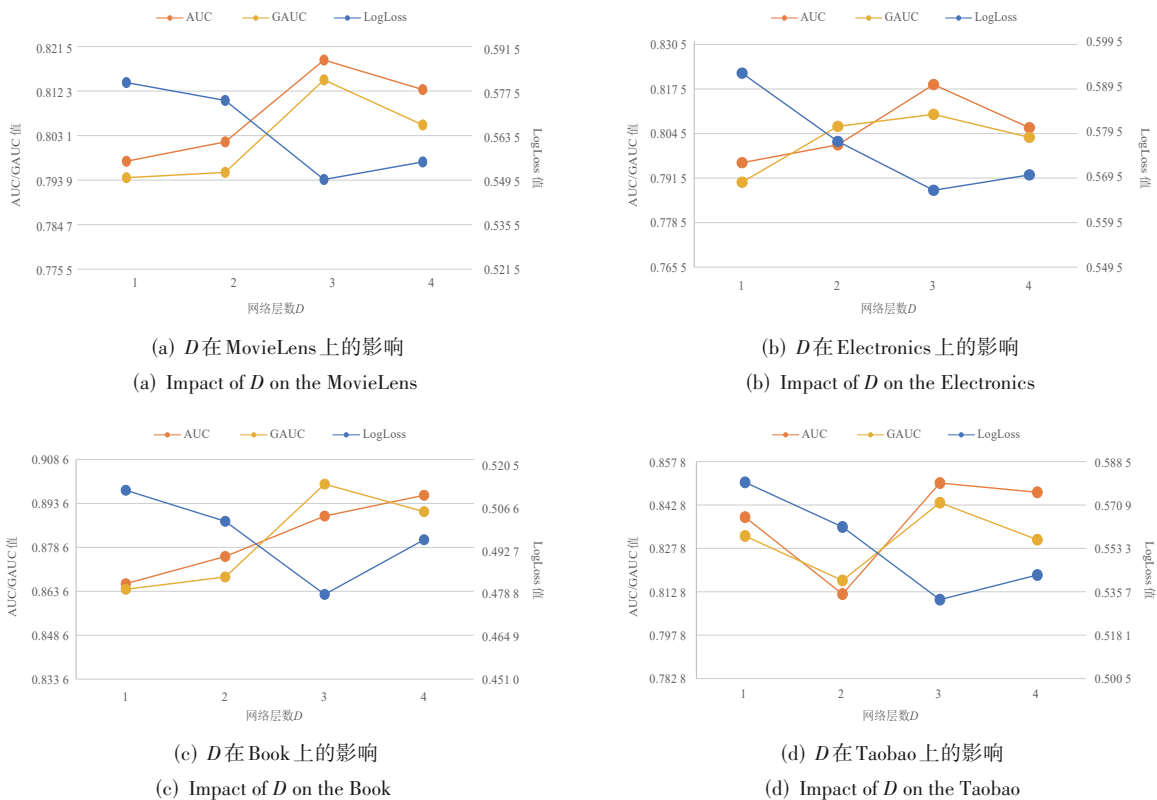


图 3 KAN 网络层数 D 的影响

Figure 3 The effect of the number of layers D in the KAN network

(3)就对比模型TWIN(在特征交互对比模型中性能最好)的时间复杂度来说,它的时间主要消耗在通道分离和交叉建模上,时间复杂度大致为 $O(n_u d + n_i d^2 + h^2 + C)$,其中 n_u, n_i 分别为用户与项目特征数, C 表示显式特征交叉计算的复杂度。

(4)就对比模型LREA(在用户兴趣对比模型中性能最好)的时间复杂度来说,其时间主要消耗在低秩分解嵌入,以及聚合长序列行为上,时间复杂度大致为 $O((N+n_i)m\bar{D}+N\bar{D}^2)$,其中 \bar{D} 代表低秩表示维度。

(5)就对比模型KarSein(在对比模型中最新且平均性能最佳)的时间复杂度来说,其时间主要消耗在使用可学习激活函数学习乘法关系上,时间复杂度大致为 $O((N^2 d + hD)(g+r+h))$ 。

综上所述,各模型时间复杂度大小关系为:本文模型HCCF-KCTR > KarSein > TWIN > LREA > AutoInt。尽管从时间复杂度上来看,HCCF-KCTR略高于对比模型,但结合表3所示的对比结果来说,本文模型的实验效果均高于其他模型,故其设计思想是合理的、有意义的。

3.4.5 模型效率分析(RQ5)

为全面评估所提模型HCCF-KCTR在实际推荐场景中的运行时间与参数规模,我们在Taobao数据集上统计了主流CTR模型的运行时间(单位:s,10轮epoch运行的平均值)与总体参数量(单位: $\times 10^6$)。统计的对比模型包括特征交互模型AutoInt和xDeepFM、用户兴趣建模模型DIEN和SIM,以及基于图结构的模型LightGCN和NRCGI。实验结果如图4所示,从图中

可看出,所提模型HCCF-KCTR在整体效率上保持了较均衡的表现。

在运行时间方面,SIM(464 s)表现最佳,得益于其高效的行为检索机制;而DIEN(671 s)与LightGCN(637 s)运行耗时较高,分别受限于复杂的兴趣演化建模与多层邻居传播;所提模型HCCF-KCTR的运行时间为559 s,低于LightGCN(637 s)、DIEN(671 s)与xDeepFM(725 s),与NRCGI(488 s)和AutoInt(598 s)接近,高于SIM(464 s),避免了深层GNN运行时间开销,同时保持了丰富的结构与语义表达能力。

在参数规模方面,DIEN(约 30.85×10^6)与xDeepFM(约 19.65×10^6)拥有较大的模型参数量,主要因为其引入复杂的序列建模或高阶交叉网络结构;LightGCN参数仅约 11.65×10^6 ,是所有对比方法中最轻量级的,其精简的线性聚合机制显著减少了参数开销;所提模型HCCF-KCTR参数量约为 14.48×10^6 ,少于大多数包含显式特征交互或长序列建模的模型,其规模高于LightGCN(约 11.65×10^6)与SIM(约 13.95×10^6),低于NRCGI(约 16.86×10^6)、AutoInt(约 17.38×10^6)、xDeepFM(约 19.65×10^6)与DIEN(约 30.85×10^6),展现出较好的结构紧凑性。

总体来看,所提模型HCCF-KCTR在运行时间与参数量之间取得了良好平衡,其效率明显优于DIEN、xDeepFM与LightGCN模型,略差于AutoInt、SIM与NRCGI模型,结合HCCF-KCTR在AUC、GAUC与LogLoss上的一致优越表现,表明所提出的结构化簇级建模与KAN非线性交互机制在保证表达能力的同时,具有较优的运行效率。

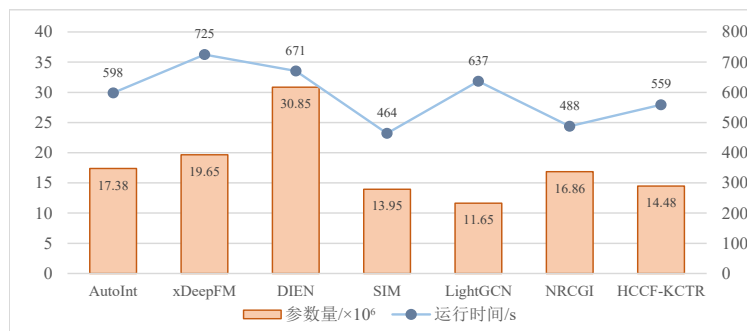


图4 各模型在Taobao数据集上的参数量和10轮epoch运行的时间均值

Figure 4 Parameter count of each model on the Taobao dataset and the average runtime over 10 epochs

4 结束语

本文提出一种融合混合社区与簇级特征的KAN架构CTR预测模型HCCF-KCTR。通过混合社区的层次化聚类获取全局与局部结构信息,利用簇级邻居特征提取模块对多跳嵌入进行层次化建模,并引入KAN网络实现高阶非线性交互表达,从而精准捕捉用户和项目间复杂的结构与语义关系,提升CTR预测性能。

(1)为充分挖掘全局与局部的社区结构特性,设计混合社区层次化聚类策略。在现有的用户-项目交互基础上,结合全局社区划分与簇内优化,将复杂交互分解为簇级关系,从而提升全局与局部交互建模的可处理性。

(2)为缓解多跳邻居带来的噪声与冗余特征,引入簇级邻居特征提取机制。基于社区划分对目标用

户与目标项目进行多跳邻居进行簇级映射,并结合簇级感知注意力池化动态调整簇内间的邻居权重,实现对不同簇群与跳级范围内邻居节点的差异化建模。

(3)为改进传统架构在结构解释性与交叉表达能力方面的不足,引入KAN-CTR预测机制。将高维复杂特征交互关系分解为多组低阶特征组合表达,显著增强模型在特征融合、非线性交叉表达与结构可解释性方面的表现,最终提升HCCF-KCTR模型预测精度与计算效率。

(4)为验证所提模型效果,展开多个综合实验分析。在4个不同的数据集上与13个经典模型进行对比,HCCF-KCTR模型在AUC、GAUC与LogLoss这3个指标值均有明显提升。同时,通过消融实验验证了各构件存在的必要性,及其协同工作的合理性与有效性。

所提模型HCCF-KCTR已取得较好的性能,但对于超长行为序列或低频交互模式,当前簇级邻居特征提取模块在簇划分上可能仍存在潜在的长尾兴趣与弱结构间的关系。下一步工作,我们将考虑设计自适应结构聚合机制,以增强模型在不同稀疏性条件下的局部语义提取与全局结构建模能力,从而进一步提升模型的鲁棒性与泛化性。

参考文献

- [1] Yang Yanwu, Zhai Panyu. Click-through rate prediction in online advertising: A literature review[J]. *Information Processing & Management*, 2022, 59(2): 102853.
- [2] Zhang Weinan, Qin Jiarui, Guo Wei, et al. Deep learning for click-through rate estimation[C]//*Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization*, 2021: 4695-4703.
- [3] He Xiangnan, Deng Kuan, Wang Xiang, 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*. New York: ACM, 2020: 639-648.
- [4] Fan Wenqi, Ma Yao, Li Qing, et al. Graph neural networks for social recommendation[C]//*The World Wide Web Conference*. New York: ACM, 2019: 417-426.
- [5] Wang Xiang, He Xiangnan, Wang Meng, et al. Neural graph collaborative filtering[C]//*Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM, 2019: 165-174.
- [6] Guo Zhiqiang, Li Jianjun, Li Guohui, et al. LGMRec: Local and global graph learning for multimodal recommendation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2024, 38(8): 8454-8462.
- [7] Liu Qiao, Zeng Yifu, Mokhosi R, et al. STAMP: Short-term attention/memory priority model for session-based recommendation[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2018: 1831-1839.
- [8] Sun Jianing, Zhang Yingxue, Guo Wei, et al. Neighbor interaction aware graph convolution networks for recommendation[C]//*Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. New York: ACM, 2020: 1289-1298.
- [9] Guo Huifeng, Tang Ruiming, Ye Yunming, et al. DeepFM: A factorization-machine based neural network for CTR prediction[C]//*Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization*, 2017: 1725-1731.
- [10] Zhou Guorui, Mou Na, Fan Ying, et al. Deep interest evolution network for click-through rate prediction[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2019, 33(1): 5941-5948.
- [11] Lian Jianxun, Zhou Xiaohuan, Zhang Fuzheng, et al. xDeepFM: Combining explicit and implicit feature interactions for recommender systems[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2018: 1754-1763.
- [12] 黄若然, 崔莉, 韩传奇. 推荐系统中稀疏情景预测的特征-类别交互因子分解机[J]. *计算机研究与发展*, 2022, 59(7): 1553-1568.
Huang Ruoran, Cui Li, Han Chuanqi. Feature-over-field interaction factorization machine for sparse contextualized prediction in recommender systems[J]. *Journal of Computer Research and Development*, 2022, 59(7): 1553-1568. (in Chinese)
- [13] Zhou Guorui, Zhu Xiaoqiang, Song Chengru, et al. Deep interest network for click-through rate prediction[C]//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. New York: ACM, 2018: 1059-1068.
- [14] Wang Ruoxi, Fu Bin, Fu Gang, et al. Deep & cross network for ad click predictions[C]//*Proceedings of the ADKDD'17*. New York: ACM, 2017: 1-7.
- [15] Liu Ziming, Wang Yixuan, Vaidya S, et al. KAN: Kolmogorov-Arnold networks[PP/OL]. V5.arXiv (2025-02-09)[2026-01-10]. <https://doi.org/10.48550/arXiv.2404.19756>.
- [16] Hao Pengyi, Qian Zhaojie, Wang Shuang, et al. Community aware graph embedding learning for item recommendation[J]. *World Wide Web*, 2023, 26(6): 4093-4108.

- [17] 邱林山, 房子荃, 陈璐, 等. 面向异质信息网络的双通道协同聚类算法[J]. 计算机学报, 2023, 46(11): 2416-2430. Qiu Linshan, Fang Ziquan, Chen Lu, et al. A bi-channel co-clustering algorithm for heterogeneous information networks[J]. Chinese Journal of Computers, 2023, 46(11): 2416-2430. (in Chinese)
- [18] Fortunato S, Hric D. Community detection in networks: A user guide[J]. Physics Reports, 2016, 659: 1-44.
- [19] 钱忠胜, 王亚惠, 俞情媛, 等. 利用伪重叠判定机制的多层循环GCN跨域推荐[J]. 软件学报, 2025, 36(9): 4327-4348. Qian Zhongsheng, Wang Yahui, Yu Qingyuan, et al. Multi-layer recurrent GCN cross-domain recommendation with pseudo-overlap detection mechanism[J]. Journal of Software, 2025, 36(9): 4327-4348. (in Chinese)
- [20] Hu Fenyu, Zhu Yanqiao, Wu Shu, et al. Hierarchical graph convolutional networks for semi-supervised node classification[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization, 2019: 4532-4539.
- [21] Chen Hong, Huang Bin, Wang Xin, et al. Global-local GraphFormer: Towards better understanding of user intentions in sequential recommendation[C]//Proceedings of the 5th ACM International Conference on Multimedia in Asia. New York: ACM, 2024: 1-7.
- [22] 钱忠胜, 黄恒, 万子珑. 融合自注意力机制的多行为图对比学习推荐方法[J]. 电子学报, 2024, 52(11): 3684-3698. Qian Zhongsheng, Huang Heng, Wan Zilong. The multi-behavior graph contrastive learning recommendation method with self-attention mechanism[J]. Acta Electronica Sinica, 2024, 52(11): 3684-3698. (in Chinese)
- [23] 李邵莹, 孟丹, 孔超, 等. 面向社交推荐的自适应高阶隐式关系建模[J]. 软件学报, 2023, 34(10): 4851-4869. Li Shaoying, Meng Dan, Kong Chao, et al. Adaptive high-order implicit relations modeling for social recommendation[J]. Journal of Software, 2023, 34(10): 4851-4869. (in Chinese)
- [24] Wu Chuhan, Wu Fangzhao, Huang Yongfeng, et al. User-as-graph: User modeling with heterogeneous graph pooling for news recommendation[C]//Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization, 2021: 1624-1630.
- [25] Hou Zhenyu, Liu Xiao, Cen YuKuo, et al. GraphMAE: Self-supervised masked graph autoencoders[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2022: 594-604.
- [26] Guo Kan, Hu Yongli, SunYanfeng, et al. Hierarchical graph convolution network for traffic forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(1): 151-159.
- [27] 陈荣元, 文杰彬, 黄少年, 等. 基于邻域与超图协作的会话推荐[J]. 电子学报, 2025, 53(8): 2805-2817. Chen Rongyuan, Wen Jiebin, Huang Shaonian, et al. Neighborhood and hypergraph collaboration for session-based recommendation[J]. Acta Electronica Sinica, 2025, 53(8): 2805-2817. (in Chinese)
- [28] Rendle S. Factorization machines[C]//2010 IEEE International Conference on Data Mining. Piscataway: IEEE, 2010: 995-1000.
- [29] Qu Yanru, Cai Han, Ren Kan, et al. Product-based neural networks for user response prediction[C]//2016 IEEE 16th International Conference on Data Mining. Piscataway: IEEE, 2016: 1149-1154.
- [30] Xiao Jun, Ye Hao, He Xiangnan, et al. Attentional factorization machines: Learning the weight of feature interactions via attention networks[C]//Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization, 2017: 3119-3125.
- [31] Song Weiping, Shi Chence, Xiao Zhiping, et al. AutoInt: Automatic feature interaction learning via self-attentive neural networks[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 1161-1170.
- [32] Wang Lei, Zhang Songheng, Wang Yun, et al. LLM4Vis: Explainable visualization recommendation using ChatGPT[PP/OL]. V2.arXiv (2023-10-16)[2026-01-10]. <https://doi.org/10.48550/arXiv.2310.07652>.
- [33] Zhang Songheng, Li Haotian, Qu Huamin, et al. AdaVis: Adaptive and explainable visualization recommendation for tabular data[J]. IEEE Transactions on Visualization and Computer Graphics, 2024, 30(9): 5923-5938.
- [34] Wang Kefan, Wang Hao, Guo Wei, et al. DLF: Enhancing explicit-implicit interaction via dynamic low-order-aware fusion for CTR prediction[C]//Proceedings of the 48th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2025: 2213-2223.
- [35] Dilbaz S, Saribas H. STEC: See-through transformer-based encoder for CTR prediction[C]//2025 IEEE 4th International Conference on Computing and Machine Intelligence. Piscataway: IEEE, 2025: 1-7.

- [36] Han Ruidong, Li Qianzhong, Jiang He, et al. Enhancing CTR prediction through sequential recommendation pre-training: Introducing the SRP4CTR framework[C]//Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. New York: ACM, 2024: 3777-3781.
- [37] Shi Yunxiao, Xu Wujiang, Zhang Haimin, et al. Beyond KAN: Introducing KarSein for adaptive high-order feature interaction modeling in CTR prediction[PP/OL]. V6. arXiv (2025-12-04) [2026-01-10]. <https://doi.org/10.48550/arXiv.2408.08713>.
- [38] Murniyati, Mutiara A B, Wirawan S, et al. Expanding Louvain algorithm for clustering relationship formation[J]. International Journal of Advanced Computer Science and Applications, 2023, 14(1).
- [39] Bei Yuanchen, Chen Hao, Chen Shengyuan, et al. Non-recursive cluster-scale graph interacted model for click-through rate prediction[C]//Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. New York: ACM, 2023: 3748-3752.
- [40] Chang Jianxin Zhang Chenbin, Fu Zhiyi, et al. TWIN: Two-stage interest network for lifelong user behavior modeling in CTR prediction at Kuaishou[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2023: 3785-3794.
- [41] Kang Yu, Pan Junwei, Jin Jipeng, et al. Towards unifying feature interaction models for click-through rate prediction[M]//Machine Learning and Knowledge Discovery in Databases. Research Track. ChamSpringer Nature Switzerland, 2025: 451-467.
- [42] Song Xin, Li Xiaochen, Hu Jinxin, et al. LREA: Low-rank efficient attention on modeling long-term user behaviors for CTR prediction[C]//Proceedings of the 48th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2025: 2843-2847.
- [43] Qi Pi, Zhou Guorui, Zhang Yujing, et al. Search-based user interest modeling with lifelong sequential behavior data for click-through rate prediction[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. New York: ACM, 2020: 2685-2692.
- [44] Xu Xiang, Wang Hao, Guo Wei, et al. Multi-granularity interest retrieval and refinement network for long-term user behavior modeling in CTR prediction[C]//Proceedings of the 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining V.1. New York: ACM, 2025: 2745-2755.

作者简介



钱志胜 男,1977年1月出生于江西省鹰潭市。2008年在上海大学获工学博士学位。江西财经大学教授,博士生导师。主要研究方向为推荐系统、人工智能、软件工程等。
E-mail: changesme@163.com



饶雨贤 女,2000年2月出生于江西省丰城市。江西财经大学计算机与人工智能学院硕士研究生。主要研究方向为推荐系统、软件工程等。
E-mail: ryxx2014@163.com




吴敏璇 女,2001年7月出生于江西省景德镇市。江西财经大学计算机与人工智能学院硕士研究生。主要研究方向为推荐系统、软件工程等。
E-mail: 1638457774@qq.com



彭劭强 男,2001年7月出生于江西省景德镇市。江西财经大学计算机与人工智能学院硕士研究生。主要研究方向为推荐系统、软件工程等。
E-mail: 2376389837@qq.com



王蓉蓉 女,2003年4月出生于江西省萍乡市。江西财经大学计算机与人工智能学院硕士研究生。主要研究方向为推荐系统、软件工程等。
E-mail: 1804193055@qq.com



许克文 男,2001年2月出生于江西省上饶市。江西财经大学计算机与人工智能学院硕士研究生。主要研究方向为推荐系统、软件工程等。
E-mail: 2576140701@qq.com