

基于MOE的自适应多视图对比推荐

贾泽露¹, 于佳恒², 温旺龙³, 肖雅夫¹, 朱凯³, 李晶³

1. 深圳市宝安区政务服务和数据管理局, 广东 深圳 518101;

2. 中冶南方工程技术有限公司, 湖北 武汉 430223;

3. 武汉大学计算机学院, 湖北 武汉 430072

摘要

近年来, 图对比学习在推荐系统中的应用取得了显著进展。然而, 当前大多数图增强策略仍依赖人工经验设计, 缺乏灵活性与泛化能力, 难以适应多样化的推荐任务和复杂的图结构。为此, 提出一种基于混合专家模型的自适应多视图对比推荐算法 (MAMGCL 算法)。该算法构建包含多种增强策略的专家池, 并引入双路门控机制实现用户侧与物品侧的专家动态融合, 进一步生成差异化增强视图, 并利用多分支图卷积网络实现节点嵌入表达, 最后结合子视图级对比学习进行优化。实验在3个真实数据集上展开, 验证了所提出方法在推荐性能和鲁棒性方面均优于现有主流对比推荐模型, 展示了较强的泛化能力与应用潜力。

关键词

推荐系统; 图对比学习; 多视图增强; 混合专家模型; 自适应机制

中图分类号: TP182

文献标志码: A

doi:10.11959/j.issn.2096-0271.2026064

Adaptive multi-view comparison recommendation based on MOE

Jia Zelu¹, Yu Jiaheng², Wen Wanglong³, Xiao Yafu¹, Zhu Kai³, Li Jing³

1. Baoan District Administrative Services Data Management Bureau of Shenzhen Municipality, Shenzhen 518101, China;

2. WISDRI Engineering & Research Inc. Ltd., Wuhan 430223, China;

3. School of Computer Science, Wuhan University, Wuhan 430072, China

Abstract

In recent years, the application of graph contrastive learning in recommendation systems has made significant progress. However, most current graph enhancement strategies still rely on manual experience design, lack flexibility and generalization ability, and are difficult to adapt to diverse recommendation tasks and complex graph structures. To this end, this paper proposes an adaptive multi-view contrastive recommendation algorithm (MAMGCL) based on a hybrid expert model. This method constructs an expert pool containing multiple enhancement strategies, introduces a two-way gating mechanism to achieve dynamic fusion of experts on the user side and the item side, further generates differentiated enhanced views, uses a multi-branch graph convolutional network to achieve node embedding expression, and finally combines sub-view-level contrastive learning for optimization. Experiments are carried out on three real-world datasets, verifying that the proposed method is superior to the existing mainstream contrastive

recommendation models in terms of recommendation performance and robustness, demonstrating strong generalization ability and application potential.

Key words

recommendation system, graph contrastive learning, multi-view enhancement, hybrid expert model, adaptive mechanism

0 引言

推荐算法作为电子商务平台的核心技术组件,其核心价值在于通过用户历史行为分析构建用户偏好模型,进而实现潜在消费需求的精准预测。该技术体系不仅优化了用户端的商品检索效能与交互体验,更显著提升了平台运营方与商户的商业价值转化效率。在匿名场景下,数据量的显著增加产生了一系列的相关难点,包括冷启动问题、数据稀疏问题、鲁棒性问题和过平滑问题等^[1],使传统基于协同过滤算法的推荐范式面临巨大挑战。由于用户与物品的交互数据存在二部图性质,当前研究多采用图结构建模方法对交互数据进行表征学习,可有效保留图数据的隐式信息用于模型训练。随着图卷积方法在聚合邻居节点性能上显著优势的展现,基于深度图卷积的推荐范式逐渐成为主流。考虑到推荐任务的稀疏性特点,对稀疏性的合理

补足成为长期以来学术界的研究热点。近年来,图结构也被用于增强模型对事实关系与潜在逻辑结构的表达能力,通过图与模型推理机制的融合,引入显式结构约束以提升复杂任务中的泛化性能,为图结构在推荐任务中的深度建模提供了新的思路^[2]。

为构建功能完备的图增强专家,本文分析了现有图对比推荐方法,并对图卷积的特殊图处理加以总结。这些方法的两种抽象概括类型如图1所示。

对于图卷积推荐方法的“图构建-图卷积-生成预测”范式,稀疏性的补足可从前两方面着手,即增强用户物品二部图数据,以及增强图卷积过程。第一类是对交互图的改动,对交互图进行增加或减少的操作以得到新的近似交互图结构,再将处理后的交互图作为数据基础进行卷积操作。已有研究表明,原始交互图中不可避免地存在噪声边和异常连接,这些问题会在图卷积传播过程中不断放大,从而影响表示学习质量。因此,针对图结构进行去噪和鲁棒性增强,被认为是缓解稀疏性和提升推荐性能的重要方向之一^[3]。如通过随机丢弃的方法临时丢掉交互图中的节点或边而形成的节点丢弃(node dropout)方法和边丢弃(edge dropout)方法^[4],通过奇异值分解(singular value decomposition, SVD)计算得到交互图的稠密近似方法^[5],以及RocSE^[6]借助邻域相似性预先对二部图数据进行去噪处理,提纯二部图中的有效信息等。但此类对原始




图1 图对比学习中常见的图增强方法

数据的主动对抗性处理必然会引入额外噪声，会面临数据增强带来的混杂效应，对稀疏数据的信息干扰可能在一定程度上破坏其原有语义结构。

第二类则不对原有交互图进行改动，而是在图卷积过程中逐层加入噪声，学术界提出了很多方案，如利用变分图重构和定制的方差估计等。如 SimGCL^[7]通过在图卷积过程中逐层加入均匀噪声，增强模型的泛化鲁棒性；NIA-GCN^[8]通过平行聚合多跳邻居的方式，挖掘同质邻居节点的交互信息。有研究指出，对比学习在图推荐任务中的性能提升并不完全依赖于复杂的图增强策略，更多来源于对表示一致性约束本身的建模能力。通过极简的视图构造与对比目标设计，模型可在稀疏交互数据下学习到更具判别性的用户与物品表示，从而验证了图对比学习范式在推荐系统中的有效性与通用性^[9]。此类方法可能会损失对推荐性能提升的解释性，但对原有交互数据的语义结构的完整保留使卷积层次向更深、更复杂的方向发展成为可能，为解决数据稀疏性问题奠定基础。

随着基于图增强的图卷积推荐方法的大量提出，如何选择合适的图增强方法成为新的难点。为解决不同图增强策略在不同数据分布和推荐场景下表现差异显著的问题，近年来有研究尝试从多视图建模的角度出发，将多种图增强结果视为不同视图，并通过对比学习机制挖掘视图间的一致性与互补性，从而提升跨场景和跨域推荐的泛化能力^[10]。本文的工作分析了物品侧和用户侧的节点密度差异性，针对性地提出了超图-扰动的图卷积对选取策略，取得了一定的推荐性能提升效果，但特定组合的策略选取会面临泛化性不足和陷入局部最优的问题。另外，混合专家 (mixture-of-experts, MoE) 模型通过

稀疏激活不同专家网络，在保证模型容量的同时有效控制计算成本，已被证明在大规模神经网络建模中具备良好的参数效率与表达灵活性，为复杂模式选择问题提供了一种可行的解决思路^[11]。考虑到混合专家模型能够突破图增强方法选择数量的桎梏和人工选用策略的局限，通过多专家网络及专家路由机制，结合图对比学习范式，匹配多视图结构与视图选择间的模式相似性，本文尝试借助 MoE 的思想，将混合专家模型的模式引入面向用户-物品交互数据的多视图对比推荐中，并提出了一种基于混合专家模型的自适应多视图对比推荐 (MoE-based adaptive multi-view graph contrastive learning, MAMGCL) 算法。此外，结合图结构检索与生成式建模的研究表明，引入结构化检索结果作为辅助信息，可以在数据有限或样本稀缺的条件下显著提升模型的判别与生成能力，这一思路为多视图推荐中不同视图信息的有效利用提供了启示^[12]。本研究旨在进一步扩展多视图对比推荐范式，通过构建多种图增强方法的专家系统池以及设计动态路由选择方法，增强其在推荐任务上的泛化性，为解决多视图对比推荐框架的视图选取策略这一挑战提供自适应方法。同时考虑到混合专家模型存在参数量较大、计算负担较重、负迁移训练问题等诸多难点，如何在利用其提升模型性能的基础上，仍维持现有推荐系统的训练与预测效率优势是一项挑战。

1 问题定义

本文的目标是根据用户与物品的交互信息，挖掘用户的兴趣偏好并生成用户可能感兴趣的物品推荐列表。以下对本文研

究的问题进行形式化定义。用户与物品之间存在点击、评论、收藏等若干种交互方式，这些交互隐含了用户对该物品的偏好。面向用户-物品交互信息的推荐系统将这些交互方式布尔化，简化考虑其存在与否后加以推理。

将单个用户节点用 u 表示，全体用户的集合表示为 $U = u_1, u_2, \dots, u_I, (|U| = I)$ ，其中 I 表示用户的总数目，即集合 U 的基数。物品用 i 表示，全体物品的集合表示为 $V = v_1, v_2, \dots, v_J, (|V| = J)$ ， J 为物品集合 V 的基数。 U 和 V 之间的历史交互数据形成的矩阵的长宽分别为用户总数和物品总数，该矩阵取值为 $\{0; 1\}$ 。将该矩阵称为交互矩阵，用 $A \in \mathbb{R}^{I \times J}$ 表示。具体地，矩阵中某一个元素 $A_{i,j}$ 的值表示第 i 个用户与第 j 个物品的交互情况。最终使预测得到的物品序列 $v_{\text{rec}} \in V$ 最接近用户实际可能感兴趣的物品。计算对每个用户的 TOP- K 项目预测的评估分数，用它评判预测器的推荐性能 $\hat{y}$ ：

$$\hat{y} = \sum_{u=1}^I \operatorname{argmax}_f(A, v_{\text{rec}}), v_{\text{rec}} \in V \quad (1)$$

输入：模型输入包括总体用户、总体物品以及全部的用户-物品交互数据，这些历史交互数据存储于稀疏矩阵 $A_{i,j}$ 。

优化过程：通过混合专家模型生成的动态图结构对数据进行推理以建模用户的兴趣偏好，训练预测器并生成推荐物品列表；通过式 (1) 所示的推荐性能的评估方法评判推荐效果以指导优化预测器。

输出：向各个既有用户推荐 TOP- K 个物品，使其接近用户的真实偏好。

2 基于混合专家模型的自适应多视图对比推荐

本文提出基于混合专家模型的自适应

多视图对比推荐。利用混合专家模型的任务特异性，针对当前任务数据的关系特性，通过门控网络为多种图增强方法赋予合适的权重，实现双侧图卷积策略的自适应选取；进而基于前述的双侧裁切范式形成推荐结果，实现具有更泛化性的推荐任务建模。MAMGCL 算法的结构框架如图 2 所示。

MAMGCL 算法的整体流程为，在每一次训练与预测时，从待优化的嵌入矩阵中，提取样本所对应用户的嵌入向量作为指导门控网络的向量，并通过双门控网络生成用户侧和物品侧的两组融合权值。将嵌入矩阵导入专家池，生成多视角的图增强信息。将融合权值分别与图增强信息相乘获得两侧图增强方案，与原交互图数据叠加获得双侧增强图。将两侧增强图 and 原交互图分别作为三支图卷积的数据基础，生成多个对比视图后，进行双侧裁切的子视图对比学习，得到双侧对比损失。读出经典图卷积生成的多层嵌入矩阵，生成预测结果并计算推荐损失。

2.1 基础多视图增强卷积框架

MAMGCL 算法遵循图对比推荐范式，如式 (2) 所示。从邻接矩阵 A 出发，先进行度标准化操作以消除节点度量纲的影响，将节点度归一化到相同的尺度：

$$A = \begin{bmatrix} 0^{U \times U} & R \\ R^T & 0^{V \times V} \end{bmatrix} \quad (2)$$

其中， R 为交互矩阵原始数据。对于逐层图卷积的嵌入矩阵 E ，其传播如式 (3) 所示：

$$E_l = D^{-\frac{1}{2}} \cdot A \cdot D^{-\frac{1}{2}} E_{l-1} \quad (3)$$

其中， E_l 和 E_{l-1} 分别代指第 l 层和第 $l-1$ 层的节点嵌入。最终用于推荐预测的读出嵌




图2 MAMGCL算法框架示意图

入为各层嵌入矩阵的堆叠：

$$\hat{E} = \text{Readout}(E_0, E_1, \dots, E_L) = \sum_{l=0}^L E_l \quad (4)$$

对于任意 L_n 层数的嵌入矩阵 $E \in \mathbb{R}^{L_n \times I + J \times D}$, D 为嵌入维度的超参数, 矩阵 E 可根据双侧节点个数裁切为用户部分 $E_u \in \mathbb{R}^{L_n \times I \times D}$ 和物品部分 $E_v \in \mathbb{R}^{L_n \times J \times D}$, 且 $E = [E_u : E_v]$ 。

推荐结果的预测值用于反向优化模型, 其得分采用贝叶斯个性化排名计算, 通过用户 u 、正样本项目 v^+ 、负样本项目 v^- 形成三元组计算偏好, 推荐损失如式 (5) 所示。

$$L_{\text{rec}} = \sum_{(u, v^+, v^-) \in \Omega} -\log \sigma(\hat{y}_{u, v^+} - \hat{y}_{u, v^-}) \quad (5)$$

2.2 图增强专家池构建

图对比学习通过生成对比视图来自监督构建样本对, 能够缓解标注数据稀疏性

问题, 而与原图卷积生成的视图略有差异的对比视图在此前研究中往往需要特殊设计。虽然多种图增强方法已证明其在图对比推荐框架上的有效性, 但人工选择的方法无法确定采用的图增强方法是否为最优选择以及其提升推荐性能的内在机制。这反映出人工选取图增强方法的技术存在较大局限性。

为在专家模型中实现对图增强方法的容纳, MAMGCL 算法综合了两类图增强思想来设计图增强专家池, 通过多种方式构建图增强专家以覆盖图增强方法的解空间, 实现对图增强专家的合理定义和对最优专家的可靠选择。同时考虑通过参数定义专家网络的数量与特征, 以实现可调节覆盖粒度的专家池。鉴于此, MAMGCL 算法从图增强生成的技术角度, 采用 3 种可学习的模型作为增强图生成的专家, 分别为多层感知机 (multilayer perceptron, MLP)、图神经网络 (graph neural

network, GNN) 和注意力机制 (attention mechanism)。这些方法能够涵盖现有诸多图增强方法。

(1) 基于多层感知机的图增强

考虑到 AMGCR 对 MLP 与 GCN 等 4 种图增强技术上的有效探索^[13], 为深入捕捉嵌入特征间的高阶交互作用, MAMGCL 算法采用 MLP 作为基础的专家模块, 并基于此推导出具有表征效能的权重矩阵 $\mathbf{W}_{\text{mlp}}$ 。该矩阵通过非线性变换层实现了嵌入空间中复杂关联关系的融合。

MLP 的多层非线性激活结构可有效学习数据中高度非线性的特征模式, 并通过参数化权重矩阵的动态调整机制, 实现嵌入交互过程的自适应优化。首先对于用户与物品的节点矩阵 $\mathbf{E}_u$ 、 $\mathbf{E}_v$, 通过两个全连接层 $\mathbf{W}_1$ 、 $\mathbf{W}_2$ 和 ReLU 函数对节点特征进行非线性变换, 具体计算如下:

$$\mathbf{X}_u = \text{ReLU}(\mathbf{E}_u \mathbf{W}_1 + \mathbf{b}_1), \mathbf{X}_v = \text{ReLU}(\mathbf{E}_v \mathbf{W}_2 + \mathbf{b}_2) \quad (6)$$

$\text{ReLU}(\cdot)$ 为赋予非线性特征的激活函数。

之后根据边索引计算边的预测值, 并使用 Sigmoid 函数将预测值映射到 $[0, 1]$ 区间:

$$\mathbf{A}_{\text{mlp}} = \text{Sigmoid}\left(\sum_{d=1}^D \mathbf{X}_u[\text{src}] \odot \mathbf{X}_v[\text{dst}]\right) \quad (7)$$

其中 src 、 dst 分别为所更新边的用户与物品节点的序号, D 为嵌入向量的维度, Sigmoid 映射函数由式 (8) 定义:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

(2) 基于图神经网络的图增强

原始用户-物品交互图中蕴含的隐式结构信息是监督信号的重要组成部分, 该信息可作为引导视图生成过程的关键先验知识, 有效抑制视图生成中产生的额外噪声。由此, 一系列图增强方法选择在图神经网络

过程中作出改动, 如 SimGCL^[7]等。为此, MAMGCL 算法的图构建专家池添加了基于图神经网络的专家模型, 通过将隐式结构特征显式编码至边权重参数空间, 使生成视图能够继承原始图拓扑的语义关联特性, 并通过多跳邻域信息传播, 在边权重计算中融合局部结构与全局上下文信息, 从而确保生成视图在保持语义连贯性的同时增强信息密度。

对于特定用户 u 和物品 v 的向量在第 l 层图卷积操作所得到的对应嵌入向量如式 (9) 所示。

$$\mathbf{r}_{i,l}^{(u)} = \bar{\mathbf{A}}_{i,*} \cdot \mathbf{E}_{l-1}^{(G)}, \mathbf{r}_{j,l}^{(v)} = \bar{\mathbf{A}}_{*,j} \cdot \mathbf{E}_{l-1}^{(G)} \quad (9)$$

与式 (7) 类似, 对 $\mathbf{A}_{\text{gen}}$ 的预测如式 (10) 所示:

$$\mathbf{A}_{\text{gen}} = \text{Sigmoid}\left(\sum_{d=1}^D \mathbf{r}_{i,l}^{(u)} \odot \mathbf{r}_{j,l}^{(v)}\right) \quad (10)$$

(3) 基于注意力机制的图增强

GAT^[8] 和 SHT^[9] 等方法均展现了注意力机制在对比视图生成过程中产生的效果。对于差异巨大的用户与不同项目的相关性, 注意力机制可以有效从庞大交互数据中辨别定位关键的交互, 由此 MAMGCL 算法的专家池加入了基于注意力机制的增强图生成专家。具体计算方法如下:

$$\mathbf{X}_u = \mathbf{E}_u \odot \mathbf{g}, \mathbf{X}_v = \mathbf{E}_v \odot \mathbf{g} \quad (11)$$

其中, $\mathbf{g} \in \mathbb{R}^{1 \times d}$ 为可学习的权重向量, 对节点嵌入进行逐元素缩放。进而基于注意力的增强图 $\mathbf{A}_{\text{att}}$ 的计算如下:

$$\mathbf{A}_{\text{att}} = \text{Sigmoid}\left(\exp\left(\sum_{d=1}^D \mathbf{X}_u[\text{src}] \cdot \mathbf{X}_v[\text{dst}]\right)\right) \quad (12)$$

其中, src 、 dst 、 D 的含义同式 (7)。由此经由专家模型可生成 3 个不同于原始交互图信息的增强图 $\mathbf{A}_{\text{mlp}}$ 、 $\mathbf{A}_{\text{gen}}$ 和 $\mathbf{A}_{\text{att}}$ 用于生成不同的对比视图。

2.3 自适应双侧专家融合

结合混合专家网络的思想，MAMGCL算法在多个增强图生成的融合中采用类似门控网络的方法，复合生成增强图 G_{aug} 。考虑到用户与物品侧的不同节点密度的结构特性，双侧应采用不同的对比视图，故设计两组结构相同但权重矩阵不共享的门控机制来生成两张不同的增强图 G_{aug1} 和 G_{aug2} 。

门控网络的基础组件为 MLP 网络，定义双侧的网络矩阵为 W_{g1} 、 W_{g2} 。为促进负载均衡，避免门控总是选择相同的专家而产生的训练不平衡乃至负迁移的现象，设计噪声增强门控以在门控计算时加以干预，加入可学习的噪声权重矩阵 W_{noise1} 、 W_{noise2} 提升鲁棒性，计算式如下：

$$h_u = \sigma(\pi^T W_{g1} + \epsilon W_{\text{noise1}}), h_i = \sigma(\pi^T W_{g2} + \epsilon W_{\text{noise2}}) \quad (13)$$

其中， $\pi \in \mathbb{R}^{1 \times d}$ 为门控网络的输入，即训练与预测时输入门控网络的信号，其定义为提供给模型的样本中用户在固定嵌入矩阵中的对应嵌入信息 $\pi_{i,0}^{(u)}$ 。为整体控制噪声矩阵的强度，设置参数 $\epsilon \sim \mathcal{N}(0, 0.1^2)$ 对其加以限制。

门控网络的输出为 $h_u, h_i \in 1 * N_{\text{exp}}$ 。考虑到图增强的全局连续性，这里将门控网络稀疏选择 Top-1 的策略修改为输出概率向量作为融合权值， $N_{\text{exp}} = 3$ 为专家网络的个数。 $\sigma(\cdot)$ 为 Softmax 函数用以归一化，使向量各个概率值之和为 1，避免系统误差。两增强图的邻接矩阵 A_{aug1} 和 A_{aug2} 可以按式 (14) 表示为：

$$A_{\text{aug1}} = \sum_{n=1}^{N_{\text{exp}}} h_u^{n-th} \cdot A_{\text{exp1}}[n], A_{\text{aug2}} = \sum_{n=1}^{N_{\text{exp}}} h_i^{n-th} \cdot A_{\text{exp2}}[n] \quad (14)$$

其中， $A_{\text{exp}} = [A_{\text{mlp}}, A_{\text{gcn}}, A_{\text{att}}]$ 表示为专家网络输出的增强图信息的组合。

2.4 多视图卷积与子视图对比

MAMGCL 算法的对比视图构建考虑到用户节点和物品节点在双侧内部具备结构异质性，设置双侧裁切的子视图对比实现对用户节点和物品节点的分别建模。设置支点图卷积模块，采用无增强的交互图数据生成基于经典 GCN 的嵌入矩阵 $E^{(G)}$ 。对于双侧专家融合模块生成的两个增强图 G_{aug1} 和 G_{aug2} ，采用式 (2) 的操作分别处理为矩阵 $A^{(U)}$ 、 $A^{(I)}$ ，再根据式 (3) 逐层生成其对应的图卷积嵌入以供后续裁切。 $E^{(A)}$ 、 $E^{(B)}$ 中的逐层逐行节点嵌入 $\alpha_{i,l}^{(u)}$ 、 $\beta_{i,l}^{(u)}$ 的传播过程可表示为：

$$\alpha_{i,l}^{(u)} = A_{i,*}^U \cdot E_{l-1}^{(G)}, \beta_{i,l}^{(u)} = A_{i,*}^I \cdot E_{l-1}^{(G)} \quad (15)$$

将 $\alpha_{i,l}^{(u)}$ 、 $\beta_{i,l}^{(u)}$ 聚合形成的嵌入矩阵定义为 $E^{(U)}$ 和 $E^{(I)}$ 。此时 $E^{(G)}$ 、 $E^{(A)}$ 和 $E^{(B)}$ 的维度均为 $(I+J) \times d \times L$ 。将 3 个矩阵根据用户数量与物品数量在第 I 个向量处进行裁切，分别取经典 GCN 分出的两部分 $E^{(GU)}$ 和 $E^{(GI)}$ ，基于 $A^{(U)}$ 生成的用户侧矩阵 $E^{(AU)}$ 和基于 $A^{(I)}$ 生成的物品侧矩阵 $E^{(BI)}$ 进行子视图级别的对比学习。对比学习的过程采用经典的对比损失 InfoNCE，计算方式如下：

$$\mathcal{L}_{\text{cl}}^{(U)} = \sum_{i=0}^I \sum_{l=0}^L - \log \frac{\exp\left(\frac{\text{sim}(\zeta_{i,l}^{(u)}, \alpha_{i,l}^{(u)})}{\tau}\right)}{\sum_{i'=0}^I \exp\left(\frac{\text{sim}(\alpha_{i,l}^{(u)}, \alpha_{i',l}^{(u)})}{\tau}\right)} \quad (16)$$

$$\mathcal{L}_{\text{cl}}^{(I)} = \sum_{j=0}^J \sum_{l=0}^L - \log \frac{\exp\left(\frac{\text{sim}(\zeta_{j,l}^{(v)}, \beta_{j,l}^{(v)})}{\tau}\right)}{\sum_{j'=0}^J \exp\left(\frac{\text{sim}(\beta_{j,l}^{(v)}, \beta_{j',l}^{(v)})}{\tau}\right)} \quad (17)$$

其中， $\zeta_{*,l}$ 指的是 $E^{(G)}$ 中的单条嵌入向量， τ

为影响损失函数敏感度的温度系数, L 是图卷积层数超参数。

2.5 推荐列表生成

将 $E^{(G)}$ 经读出操作得到的向量 $\hat{E}^{(G)}$ 输入式 (5), 计算得出最终的推荐损失 $\mathcal{L}_{\text{rec}}$ 。结合对比损失 $\mathcal{L}_{\text{cl}}$ 以及 L_2 正则项 $\mathcal{L}_{\text{reg}}$, 实现整体优化的损失函数的计算:

$$\begin{aligned} \mathcal{L}_{\text{total}} = \mathcal{L}_{\text{rec}} + \lambda_c(\mathcal{L}_{\text{cl}}) + \lambda_r(\mathcal{L}_{\text{reg}}) = \\ \mathcal{L}_{\text{rec}} + \lambda_c(\mathcal{L}_{\text{cl}}^{(U)} + \mathcal{L}_{\text{cl}}^{(I)}) + \lambda_r(\|\Theta\|_F^2) \end{aligned} \quad (18)$$

其中, λ_c 和 λ_r 分别为对比损失和正则项的权重。

3 实验与分析

3.1 实验设计

本文提出的 MAMGCL 算法以混合专家模型方法为核心, 并根据任务特点在专家池构建、专家训练和专家选择策略等诸多方面作出一系列相关改进。对于上述模块与技术的合理性与有效性, 将在两个常用的数据集上通过多种方式加以实验验证。具体验证问题与方法如下:

- 为整体验证 MAMGCL 算法在真实场景推荐任务上的性能, 在公开数据集上与基线算法做对比实验;
- 为验证双侧专家融合策略的有效性,

设计相关的消融实验并设计 3 种消融变体以对比参考;

- 为验证各个专家池模型的作用效果, 设计去除若干专家模型的消融实验;
- 为探究超参数取值选择对模型性能的影响, 设计超参数实验进行评估。

3.1.1 数据集

为了对比结果的公平性, 本文对模型的评估建立在 3 个学术界广泛采用的、取自真实商业平台的公共数据集: Yelp 数据集、Last.FM 数据集和 BeerAdvocate 数据集。3 个数据集的数据规模的具体细节见表 1。

Yelp: Yelp 数据集是一个广泛用于推荐系统研究的公开数据集, 包含丰富的用户-商家的签到、点评交互数据。

Last.FM: Last.FM 数据集是一个公共音乐推荐数据集, 记录了用户听歌历史、标签和社交互动等信息。

BeerAdvocate: 该数据集包含来自 BeerAdvocate 的啤酒评论。

3.1.2 基线方法

为全面评估算法性能, 本文选择了面向用户-项目交互数据的图协同过滤推荐领域若干经典算法, 将这些推荐算法作为基线模型, 与本文 MAMGCL 算法进行推荐性能对比。本文实验在两个公开数据集上开展。

• **NGCF^[14]:** 一种基于图的协同过滤算法, 在消息传递过程中整合了二阶交互信息以生成向量特征。

• **LightGCN^[15]:** 一种经典的轻量化图卷积推荐算法, 在卷积层仅进行邻域聚合一个操作, 提升训练效率和泛化性能。

• **SLRec^[16]:** 将对比学习引入推荐系

表1 数据集规模细节

数据集	用户数	物品数	交互数	数据密度
Yelp	42 712	26 822	182 357	1.6×10^{-4}
Last.FM	1 892	17 632	92 834	2.8×10^{-3}
BeerAdvocate	10 456	13 845	1 381 094	9.5×10^{-4}

统来统一两种增强嵌入的方法，验证数据增强在推荐任务的稀疏数据上的有效性。

- **HCCF^[17]**: 一种借助超图学习全局依赖信息的自监督推荐算法，采用跨视图的对比学习来同时捕获并整合局部信息和全局信息。

- **SHT^[18]**: 一种将 Transformer 架构引入超图推荐的推荐算法，通过较大的参数量有效提升推荐性能。

- **SGL^[4]**: 一种结合 3 种不同图增强方法的图对比推荐，在训练过程的每一轮次从节点丢弃、边丢弃、随机游走中随机选用，再在对比学习中将信息整合。

- **SimGCL^[7]**: 一种直接将噪声引入图卷积而无需其他图增强方法的图对比学习，限制噪声随机均匀分布于超球面。

- **AFDGCF^[19]**: 一种动态地对表示矩阵的特征维度施加相关惩罚，针对性缓解过度相关和过度平滑问题的模型无关方法。本文选用 AFDGCF 系列模型中效果最好的 AFD-LightGCN 模型。

- **BusGCL^[20]**: 该算法考虑到用户节点和物品节点两侧的密度非对称性，通过双侧子视图裁切多视图的对比学习获得更好的节点特征建模。

3.1.3 评估指标

为了合理地与基线算法进行对比，本文设定 TOP-20 和 TOP-40 的推荐列表长度，对应的性能度量采用召回率 Recall@20 和 Recall@40，以及归一化折扣累计增益 NDCG@20 和 NDCG@40。Recall@K(u) 和 NDCG@K(u) 的计算方式如下：

$$\text{Recall@K}(u) = \frac{|R(u) \cap T(u)|}{|T(u)|} \quad (19)$$

其中， $R(u)$ 是对用户 u 推荐的 TOP- K 个物品集合， $T(u)$ 是用户 u 在测试集上喜欢的

物品集合。

$$\text{NDCG@K}(u) = \frac{\text{DCG@K}(u)}{\text{IDCG@K}(u)} \quad (20)$$

其中，

$$\text{DCG@K}(u) = \sum_{i=1}^K \frac{\text{rel}(i)}{\log_2(i+1)} \quad (21)$$

$\text{rel}(i)$ 是第 i 个推荐商品的真实相关性分数。IDCG@K(u) 是理想情况下的 DCG，是将推荐列表的相关性分数从高到低排序后计算的 DCG 值，计算式与 DCG@K 类似，只是将 $\text{rel}(i)$ 替换为排序后的相关性分数 $\text{rel}(i, \text{sorted})$ 。全局 Recall@K 和 NDCG@K 将所有用户的 Recall@K(u) 和 NDCG@K(u) 取平均值即可。其中，Recall@K 表示在用户所有感兴趣的商品中，被成功推荐到前 K 位的比例。NDCG@K 表示推荐列表前 K 位的排序质量，值越接近 1，说明越相关的内容被排得越靠前。

3.1.4 参数设置

MAMGCL 算法旨在设计自适应性高的多视图对比模型，故引入的超参数较少。具体来说，设置损失函数中对比损失项权重 λ_c 从 $\{1 \times 10^{-3}, 5 \times 10^{-2}, 1 \times 10^{-2}, \dots, 50, 100\}$ 调优， λ_r 取值于范围为 $\{1 \times 10^{-6}, 1 \times 10^{-5}, 1 \times 10^{-4}, 1 \times 10^{-3}\}$ ，图卷积层数 L 从 $\{1, 2, 3, 4, 5, 6, 7, 8, 9, 10\}$ 中取值，而对比学习中 InfoNCE 计算式内出现的温度系数 τ 的范围为 $\{0.01, 0.1, 1, 10\}$ 。本文的实验在 Python 3.10 环境中编码，基于深度学习框架 PyTorch 2.1 运行实现。

3.2 推荐性能

各基线方法评估指标均选用原论文给

出的最优成绩。如原论文未给出本章实验采用的数据集，则在自监督学习框架 SSLRec 内重新实验，并根据原论文给出的超参数取值范围进行网格搜索以取得最优值。最终基于 Yelp 的评价性能见表 2，Last.FM 的性能见表 3，BeerAdvocate 的

性能见表 4。

传统的方法，如 NGCF 和 LightGCN，缺乏图增强和对比学习对数据稀疏性的有效处理，导致其相对于后续出现的诸多方法推荐效果较差。这说明图增强技术在基于稀疏交互的推荐任务中效果良好，具有深入研究的前景。

HCCF 和 SHT 均采用了基于超图卷积的对比视图，其中 SHT 在前者的基础上增加了基于注意力机制的 Transformer 方法赋能图增强，取得了一定的性能提升。这说明注意力机制能够在传统图增强方法基础上学习到额外的有助于建模用户偏好的知识，这也是 MAMGCL 算法的专家池设计中采用注意力机制的原因。同时对比前两个模型与 BusGCL 模型的性能差异，反映了超图方法的有效性具有双侧拮抗的局限性，故 MAMGCL 算法没有选用单独用超图技术设计的专家模块。

SGL 取得了较好的成绩，尤其是在 $K=40$ 的各项指标上取得了有竞争力的预测分数，这说明了多图增强生成模式在图对比推荐范式上的有效性，即使采用比较基础的节点丢弃、随机游走等增强方法仍具备较好的建模与推荐能力。SGL 的有效性也从机制上解释了 MAMGCL 算法的优势：其图生成专家模型能够更全面地覆盖空间特征，从而获得更好的推荐能力。

与以上诸基线方法相比，MAMGCL 算法在两个数据集的全部指标上均获得了最优的预测精度，包括与 AFDGCF 等近年来新提出的推荐方法相比仍具备较大的优势，这说明基于混合专家模型思想的多图卷积嵌入融合能够在面向交互数据的推荐任务中取得良好效果。对比各个指标与次优值的提升度，可以注意到 MAMGCL 算法在 NDCG 值上的提升幅度较大，意味着得出的推荐序列有较好的次序，这反映了动态

表 2 Yelp 数据集上的推荐性能

算法	Yelp			
	Recall@	Recall@	NDCG@	NDCG@
	20 ↑	40 ↑	20 ↑	40 ↑
NGCF ^[10]	0.068 1	0.101 9	0.033 6	0.041 9
LightGCN ^[11]	0.076 1	0.117 5	0.037 3	0.047 4
HCCF ^[13]	0.078 9	0.118 5	0.039 9	0.049 6
SHT ^[21]	0.079 4	0.121 7	0.039 5	0.049 7
SLRec ^[12]	0.066 5	0.103 2	0.032 7	0.041 8
SGL ^[2]	0.080 3	0.122 6	0.039 8	0.050 2
SimGCL ^[5]	0.081 3	0.123 0	0.040 8	0.051 0
AFDGCF ^[21]	0.081 1	0.125 7	0.038 4	0.049 7
BusGCL ^[5]	0.084 0	0.126 3	0.042 4	0.052 8
MAMGCL	0.086 8	0.128 6	0.044 1	0.054 6

表 3 Last.FM 数据集上的推荐性能

算法	Last.FM			
	Recall@	Recall@	NDCG@	NDCG@
	20 ↑	40 ↑	20 ↑	40 ↑
NGCF ^[10]	0.208 1	0.294 4	0.147 4	0.182 9
LightGCN ^[11]	0.234 9	0.322 0	0.170 4	0.202 2
HCCF ^[13]	0.241 0	0.323 2	0.177 3	0.205 1
SHT ^[21]	0.242 0	0.323 5	0.177 0	0.205 5
SLRec ^[12]	0.195 7	0.279 2	0.144 2	0.173 7
SGL ^[2]	0.242 7	0.340 5	0.176 1	0.210 4
SimGCL ^[5]	0.239 8	0.333 7	0.178 0	0.209 9
AFDGCF ^[21]	0.163 8	0.261 7	0.103 3	0.136 3
BusGCL ^[5]	0.248 7	0.340 3	0.183 7	0.214 7
MAMGCL	0.252 9	0.343 0	0.188 3	0.221 0

路由融合的机制能够对嵌入组合赋予更细微的特征表示，这是直接沿用混合专家模型的稀疏选择方式达不到的。

3.3 消融实验

3.3.1 对双侧专家融合策略的消融

MAMGCL算法为同时保有多个专家模型的细微知识，选择在经典 MoE 框架的门控网络路由机制上优化为非稀疏激活的动态融合方法。为验证该优化的有效性，设计了关于双侧专家融合策略的消融。具体结果见表 5。表 5 中变体标记-S 代表采用单一路由，即消融双路由裁切模块；标记-G 代表采用稀疏选择的门控网络，消融动态融合机制。

MAMGCL 算法与所有消融变体相比，在全部数据集上均有更好的结果，说明双侧路由和动态融合两机制的同时采用是有效的。与 MAMGCL-SG 相比，MAMGCL-G 和 MAMGCL-S 性能上普遍较好，说明两模块均有对推荐性能的贡献。虽然 MAMGCL-G 仅采用门控机制选择单一专家模型的嵌入视图加入对比，但仍取得了较高的得分，这进一步说明了混合专家模型的模式具备较好的推荐潜力。

3.3.2 对专家模型池的消融

MAMGCL 算法的专家池创建了基于多

表 4 BeerAdvocate 数据集上的推荐性能

算法	BeerAdvocate			
	Recall@	Recall@	NDCG@	NDCG@
	20 ↑	40 ↑	20 ↑	40 ↑
NGCF ^[10]	0.103 3	0.165 3	0.087 3	0.103 2
LightGCN ^[11]	0.110 2	0.175 7	0.094 3	0.111 3
HCCF ^[13]	0.115 6	0.184 7	0.099 0	0.117 6
SHT ^[21]	0.115 0	0.179 9	0.097 7	0.115 6
SLRec ^[12]	0.104 8	0.172 3	0.088 1	0.106 8
SGL ^[2]	0.113 8	0.177 6	0.095 9	0.112 2
SimGCL ^[5]	0.118 9	0.179 8	0.099 7	0.115 8
AFDGCN ^[21]	0.112 1	0.174 3	0.092 4	0.110 1
BusGCL ^[5]	0.119 7	0.181 1	0.101 1	0.118 9
MAMGCL	0.121 5	0.183 9	0.102 8	0.121 3

层感知机、基于图神经网络和基于注意力机制的 3 种图增强专家模型，为验证 3 种专家模型各自的必要性和贡献，在此进行专家模型的消融实验。结果见表 6。其中根据 3 种专家模型的存在与否，形成 7 种不同的变体。变体的命名根据存在的专家模型在下标予以标记。

在所有变体当中，同时包含 3 种图生成专家模型的 MAMGCL 算法具有最好的效果，这说明同时采用 3 种图生成机制能够最好地覆盖图增强技术的解空间，体现了为对推荐任务中节点间关系进行最优拟合与建模的能力，同时动态路由机制有效激活，所有的专家模型均参与到融合嵌入

表 5 对双侧专家融合策略的消融

变体	是否双侧	是否融合	Yelp		Last.FM		BeerAdvocate	
			Recall@20	NDCG@20	Recall@20	NDCG@20	Recall@20	NDCG@20
MAMGCL-SG	否	否	0.071 6	0.035 2	0.209 5	0.144 8	0.108 6	0.084 9
MAMGCL-G	是	否	0.076 1	0.037 5	0.215 2	0.160 5	0.110 7	0.091 7
MAMGCL-S	否	是	0.080 4	0.040 9	0.231 0	0.173 1	0.117 9	0.099 4
MAMGCL	是	是	0.086 8	0.044 1	0.252 9	0.188 3	0.121 5	0.102 8

构建当中，未出现某一专家网络坍塌，权重长期过低而退化为更少视图的变体模型的情况。MAMGCL_{mg}与MAMGCL_{ga}有较好的效果，图卷积能够生成有效的专家视图。

3个单一专家模型的变体MAMGCL_g、MAMGCL_m和MAMGCL_a得到了较差的结果，单一专家模型难以覆盖多样化的增强图卷积，而且意味着并无专家融合与双侧子视图等机制，这对推荐性能的负面影响是显著的。3个有两个专家模型的变体的得分差异表明了3个专家模型对推荐性能的贡献，即在当前任务中未出现专家模型

失效的模型坍塌现象。

3.4 超参数研究

(1) 图卷积层数分析

图卷积层数是影响基于GCN的推荐算法的重要因素，为分析其变化趋势以及调优性能，结合实际测试情况，将层数从{1, 2, 3, ..., 10}中分别取值并验证在3个数据集上的推荐得分。实验结果如图3所示。

根据实验结果可知，层数取值为1时算法性能很差，表明图卷积模块在聚合邻居节点信息不足时会极大地影响其能力。

表6 对专家模型池的消融

变体	A _{mlp}	A _{gcn}	A _{att}	Yelp		Last.FM		BeerAdvocate	
				Recall@20	NDCG@20	Recall@20	NDCG@20	Recall@20	NDCG@20
MAMGCL _a	否	否	是	0.0569	0.0256	0.1783	0.1142	0.0988	0.00776
MAMGCL _g	否	是	否	0.0699	0.0327	0.2021	0.1336	0.1009	0.0899
MAMGCL _m	是	否	否	0.0312	0.0163	0.1359	0.0945	0.0597	0.0489
MAMGCL _{mg}	是	否	是	0.0815	0.0385	0.2416	0.1801	0.1151	0.0946
MAMGCL _{ga}	否	是	是	0.0841	0.0406	0.2474	0.1808	0.1187	0.0994
MAMGCL _{ma}	是	是	否	0.0802	0.0375	0.2382	0.1764	0.1138	0.0931
MAMGCL	是	是	是	0.0868	0.0441	0.2529	0.1883	0.1215	0.1028




图3 图卷积层数分析

在 Yelp 和 BeerAdvocate 数据集上层数达到 3 层时接近最优值，在数据量偏小的 Last.FM 数据集上初步达到较优得分的层数为 2，这与此前对基于 GCN 的推荐模型的研究工作得出的普遍结论是契合的。三阶的邻居节点聚合基本满足目前水平的推荐模型获取较为充分的隐式交互信息，而覆盖更少的交互需要的邻居跳数也更少。MAMGCL 算法在层数进一步增多的过程中始终维持稳定的推荐成绩，即模型在抗平滑方面具备良好性能，这说明了增强图实施动态聚合的有效性。

(2) 对比损失权重分析

图对比学习中对比损失权重的设置对整体性能影响很大。将对比权重 λ_c 从 $\{1 \times 10^{-3}, 5 \times 10^{-2}, 1 \times 10^{-2}, \dots, 50, 100\}$ 中分别取值并在 3 个数据集上验证其推荐能力。实验结果如图 4 所示。

对比损失权重较小时，其增大与模型的推荐性能呈正相关，这表明了对比学习的有效性。综合来看，对比权重取值在 1 附近时具有较优的推荐得分，此时推荐损失和对比损失的实际数值也比较平衡，可使两损失函数均有效作用于模型优化。当对比损失过大时，模型性能急剧下降，说

明损失函数中损失项失衡会破坏模型的训练效果。

4 结束语

本文在前人研究的基础上，进一步深入探索如何增强图对比范式的泛化性，以应对推荐任务中的数据稀疏性与异质性。为解决普遍采用人工设定策略缺乏自适应性这一问题，本文提出了 MAMGCL 算法，其通过路由机制从一系列专家模型中自适应地选择两侧图增强方法，将图增强策略从人工选择中解放出来，有效增强了多视图对比推荐算法在不同数据背景上的泛化性，并提高了算法的应用价值。本文充分验证了 MAMGCL 算法的推荐性能，通过消融实验验证了 MAMGCL 算法各模块的贡献，证明了自适应双侧对比视图生成方法能够有效应用于图对比推荐中，在现实推荐任务中能够发挥良好的作用。

参考文献：

[1] 刘天航, 杨晓雪, 周慧, 等. 基于图神经网络




图4 对比损失权重分析

- 的协同过滤推荐算法综述[J]. 集成技术, 2024, 13(4): 1-15.
- Liu T H, Yang X X, Zhou H, et al. A survey of collaborative filtering recommender algorithms based on graph neural networks[J]. Journal of Integration Technology, 2024, 13(4): 1-15.
- [2] 杨娟, 沈游人. 图模融合: 人工智能系统事实表达和逻辑推理增强[J]. 大数据, 2025, 11(1): 175-190.
- Yang J, Shen Y R. Graph-LLM fusion: enhancing fact representation and logical reasoning in artificial intelligence systems[J]. Big Data Research, 2025, 11(1): 175-190.
- [3] Luo D S, Cheng W, Yu W C, et al. Learning to drop: robust graph neural network *via* topological denoising[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining. New York: ACM, 2021: 779-787.
- [4] Wu J C, Wang X, Feng F L, et al. Self-supervised graph learning for recommendation[C]//Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2021: 726-735.
- [5] Cai X, Huang C, Xia L, et al. Lightgcl: simple yet effective graph contrastive learning for recommendation[C]//The 11th International Conference on Learning Representations. [S.l.:s.n.], 2023.
- [6] Ye H B, Li X J, Yao Y, et al. Towards robust neural graph collaborative filtering *via* structure denoising and embedding perturbation[J]. ACM Transactions on Information Systems, 2023, 41(3): 1-28.
- [7] Yu J L, Yin H Z, Xia X, et al. Are graph augmentations necessary? : simple graph contrastive learning for recommendation[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 1294-1303.
- [8] Sun J N, Zhang Y X, Guo W, 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] Yu J L, Xia X, Chen T, et al. XSimGCL: towards extremely simple graph contrastive learning for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(2): 913-926.
- [10] Xu Z T, Chen S, Pan W K, et al. A multi-view graph contrastive learning framework for cross-domain sequential recommendation[J]. ACM Transactions on Recommender Systems, 2025, 3(4): 1-28.
- [11] Shazeer N, Mirhoseini A, Maziarz K, et al. Outrageously large neural networks: the sparsely-gated mixture-of-experts layer[PP]. V1. arXiv (2017-01-23)[2025-12-30]. arXiv:1701.06538.
- [12] 刘天扬, 寇思佳, 金旭, 等. 基于图检索增强生成和少样本学习的美术作品鉴赏[J]. 大数据, 2025, 11(5): 101-116.
- Liu T Y, Kou S J, Jin X, et al. Art appreciation based on graph retrieval augmented generation and few-shot learning[J]. Big Data Research, 2025, 11(5): 101-116.
- [13] Yang M D, Yuan Y, Zhou J, et al. Adaptive fusion of multi-view for graph contrastive recommendation[C]//Proceedings of the 18th ACM Conference on Recommender Systems. New York:

ACM, 2024: 228–237.

[14] Wang X, He X N, Wang M, 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.

[15] Sun J N, Zhang Y X, Guo W, 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.

[16] Yao T S, Yi X Y, Cheng D Z, et al. Self-supervised learning for large-scale item recommendations[C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York: ACM, 2021: 4321–4330.

[17] Xia L H, Huang C, Xu Y, et al. Hyper-graph contrastive collaborative filtering [C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 70–79.

[18] Xia L H, Huang C, Zhang C X. Self-supervised hypergraph transformer for recommender systems[C]//Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: ACM, 2022: 2100–2109.

[19] Wu W, Wang C, Shen D Z, et al. AFDGCF: adaptive feature de-correlation graph collaborative filtering for recommendations[C]//Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2024: 1242–1252.


[20] Yu J H, Li J, He Y, et al. Bilateral unsymmetrical graph contrastive learning for recommendation[C]//Proceedings of the 2024 International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2024: 1–8.

[21] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[C]//International Conference on Learning Representations. [S.l.:s.n.], 2018.

作者简介



贾泽露（1977–），男，博士，深圳市宝安区政务服务和数据管理局副教授/高级工程师，主要研究方向为空间地理信息、知识数据工程 and 信息系统智能化。




于佳恒（2000–），男，就职于中冶南方工程技术有限公司，主要研究方向为协同过滤推荐算法。



温旺龙（2002-），男，武汉大学计算机学院硕士生，主要研究方向为多模态可解释性推荐算法。



肖雅夫（1988-），男，博士，就职于深圳市宝安区政务服务和数据管理局，主要研究方向为大数据与人工智能应用、知识数据工程。



朱凯（1995-），男，武汉大学计算机学院博士生，主要研究方向为生成式序列推荐算法。



李晶（1967-），男，博士，武汉大学计算机学院教授，主要研究方向为推荐算法、目标跟踪、人脸识别。

录用日期: 2025-12-30
通信作者: 于佳恒, 912855828@qq.com; 李晶, leejingcn@whu.edu.cn
基金项目: 国家自然科学基金资助项目(No.62372335)
Foundation Items: The National Natural Science Foundation of China (No.62372335)