



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目: 跨通道自监督增强的超图群组推荐模型
作者: 史艳翠, 韩香玉
DOI: 10.13364/j.issn.1672-6510.20250173
收稿日期: 2025-11-15
网络首发日期: 2026-09-02
引用格式: 史艳翠, 韩香玉. 跨通道自监督增强的超图群组推荐模型[J/OL]. 天津科技大学学报. <https://doi.org/10.13364/j.issn.1672-6510.20250173>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。



跨通道自监督增强的超图群组推荐模型

史艳翠, 韩香玉

(天津科技大学人工智能学院, 天津 300457)

摘要: 随着旅游组队、线上观影等多人共决策的应用迅速普及, 群组推荐成为了缓解群体信息过载的工具, 而现有的群组推荐方法往往忽略组内和组间的高阶协作关系, 并存在数据稀疏性的问题。为此, 本文提出跨通道自监督增强的超图群组推荐模型 (HGRS)。该模型包含用户级行为通道和群组级行为通道。在用户级行为通道中, 构建用户-项目超图与用户-用户社交图的异构图结构, 联合建模用户交互行为与社交影响力; 在群组级行为通道中, 基于三元组模式构建了群组级超图并计算了超边权重, 深入挖掘群组间的高阶交互关系。最后, 为缓解数据稀疏性问题, 将自监督学习技术整合到模型中, 通过在两个通道间建立互补的信息流, 有效增强群组表示。在 Mafengwo 和 CAMRa2011 数据集上进行实验验证, 结果表明本文模型具有更好的推荐性能。

关键词: 群组推荐; 超图卷积网络; 异构图; 自监督学习

中图分类号: TP391 **文献标志码:** A **文章编号:** 1672-6510 (0000)00-0000-00

Hypergraph Group Recommendation Model Enhanced by Cross-Channel Self-Supervised Learning

SHI Yancui, HAN Xiangyu

(College of Artificial Intelligence, Tianjin University of Science and Technology, Tianjin 300457, China)

Abstract: With the rapid popularity of multi-party decision-making applications such as group travel planning and online movie watching, group recommendation has become a key tool for alleviating collective information overload. Existing methods, however, often overlook the high-order collaborative relationships both within and across groups and suffer from data sparsity. To address these issues, we propose the hypergraph group recommendation model enhanced by cross-channel self-supervised learning (HGRS). The model comprises a user-level behavior channel and a group-level behavior channel. In the user-level channel, we construct a heterogeneous structure that couples a user-item hypergraph with a user-user social graph to jointly capture user interactions and social influence. In the group-level channel, we build a group-level hypergraph following a triplet pattern and compute hyperedge weights to mine high-order inter-group interactions. Finally, to mitigate data sparsity, self-supervised learning is integrated to establish complementary information flows between the two channels, effectively enhancing group representations. Experiments on the Mafengwo and CAMRa2011 datasets demonstrate that this model achieves superior recommendation performance.

Keywords: group recommendation; hypergraph convolutional network(HGCN); heterogeneous graph; self-supervised learning

收稿日期: 2025-11-15; 修回日期: 2026-03-29

基金项目: 国家自然科学基金资助项目(62377036)

作者简介: 史艳翠(1982—), 女, 河北保定人, 副教授, syc@tust.edu.cn

推荐系统作为解决信息过载的有效技术,已广泛应用到电子商务、社交网络和娱乐软件等多个领域^[1]。过去的推荐系统大多针对单个用户设计,无法满足多样化的群体需求。因此,面向群组的推荐系统应运而生,现已成为推荐领域的研究热点。群组推荐系统的主要工作是整合群体中用户的个体偏好,用有效的方法调和偏好间的差异^[2]。模型设计不仅能够融合不同用户偏好的策略,保证推荐的内容能使大多数人满意,还要解决如何在保持个体差异性的同时,实现群体偏好平衡的问题。早期的群组推荐系统通过预定义的融合机制确定群组的偏好表示,再结合个性化推荐方法和简单的聚合策略(如平均或加权求和)完成群组推荐任务^[3]。这种方式简单有效,但不能从交互数据中自适应地学习用户间、用户与群组间的影响权重。因此,研究者引入了概率模型,用潜在变量表示用户对群组或其他用户的影响权重。然而,这些方法在一定程度上依赖对先验分布的假设,例如 PIT(personal impact topic)模型^[4]假设最重要的用户对群体决策具有高影响,COM(consensus model)模型^[5]则假设用户的影响权重取决于其所决定的主题,但这些模型都忽略了同一个用户在不同群体中的影响权重可能不一样。

随着深度神经网络技术在群组推荐领域的应用,给该领域带来了新发展。Cao 等^[6]首次把注意力模型应用到群组推荐中,提出注意力群组推荐模型(AGREE),该模型根据输入数据动态地学习融合策略。Deng 等^[7]构建了将知识图谱与神经注意力结合起来的模型(KGAG),引入外部知识建立不同项目间的关联关系。Zhang 等^[8]构建了异构图注意力网络模型(HetGRec),以元路径随机游走重启机制生成相关性高的邻居子图,再通过双层注意力网络聚合邻居节点信息。这些模型都取得了很好的推荐效果,但许多模型都偏向于对单个群组内的用户偏好进行建模,忽略了群组内部和群组间更复杂的高阶协作关系。

针对上述问题,本文提出跨通道自监督增强的超图群组推荐模型(hypergraph group recommendation model enhanced by cross-channel self-supervised learning, HGRS)。模型设计了用户级行为通道和群组级行为通道。在用户级行为通道中,构建用户-项目超图和用户-用户社交图的异构图结构,利用超图卷积网络(hypergraph convolutional network, HGCN)捕捉用户与项目间复杂的高阶协作关系,同时采用注意力聚合机制获取用户在组外

的社交影响力。在群组级行为通道中,先把用户级的超图转换成投影图,再采用三元组模式选择群组级超图中最相关的群组,将这些群组定义为一个由模式诱导的超边,使用 HGCN 学习群组间的高阶关系。最后,考虑到数据稀疏会影响超图建模的效果,使用跨通道自监督学习缓解数据稀疏带来的问题。

1 相关工作

1.1 基于 HGCN 的群组推荐

在群组推荐的相关研究中,图卷积网络(GCN)因处理图结构数据的能力很强而被广泛应用^[9-11],但仅能建模成对关系,无法捕捉多节点间的高阶交互关系,HGCN 的出现为高阶关系建模提供了新思路 Jia 等^[12]采用超图模拟群组中错综复杂的数据关系,从而有效捕获群组、用户以及项目间的高阶相关性。Chen 等^[13]把群组用户映射到统一超立方体空间,再用 HGCN 捕获高阶交互,在保证信息损失最小的前提下,完成了群组偏好的聚合。Guo 等^[14]提出一种层次化的超边嵌入表示学习框架,通过构建用户-项目的超图结构,采用图神经网络学习用户行为,以此提升推荐系统的准确性。王聪等^[15]通过构建超图、二分图和投影图,从用户、群组和全局 3 个视角提取群组偏好,并采用 HGCN 建模用户、项目、群组间的高阶关系。然而,这些研究仅关注于群组内部用户-项目的高阶交互,忽视了群组间的高阶关系,未能挖掘群组间潜在的间接协作关系。针对这一问题,本文设计了双行为通道,将用户级超图与群组级超图相结合,用户级超图建模组内用户-项目协同偏好与用户社交影响的微观高阶关系,群组级超图挖掘群组间直接与间接的宏观高阶关系,实现组内、组间高阶关系的协同建模。

1.2 自监督学习

自监督学习把未标记的数据转换成监督信号,为提升模型性能提供了新方向^[8,16]。在群组推荐领域中,Wei 等^[17]随机对群组-用户交互边进行掩码处理,生成带有扰动的视图,然后对齐掩码前后群组表示构建自监督信号;Li 等^[18]通过随机移除群组用户节点进行数据增强,并对移除前后的群组表示进行对齐,但这种方法会删掉关键用户。为了避免丢失重要信息,本文提出了跨通道自监督学习,无需破坏原始图结构,而是在两个通道上分别编码群组,通过最大化双通道学习到的群组表示的互信息构建自监督信号。这种方式既保留了全部的用户信息,又能利用互补信息有效缓解数据稀疏性问题。

2 相关定义

2.1 问题定义

用户集合表示为 $U=\{u_1, \dots, u_m, \dots, u_{|U|}\}$, 项目集合表示为 $I=\{i_1, \dots, i_n, \dots, i_{|I|}\}$, 群组集合表示为 $G=\{g_1, \dots, g_t, \dots, g_{|G|}\}$, 其中 $|U|$ 、 $|I|$ 、 $|G|$ 分别表示用户、项目、群组的数量。将所有用户嵌入到 d 维向量空间中, 初始化为 $\bar{U}=\mathbf{R}^{|U| \times d}$ 。同理, 项目表示为 $\bar{I}=\mathbf{R}^{|I| \times d}$, 群组表示为 $\bar{G}=\mathbf{R}^{|G| \times d}$ 。

群组推荐的任务是给定目标群组 g_t , 为其生成候选项目得分序列 $Y=\{y_1, \dots, y_i, \dots, y_{|Y|}\}$, y_i 存储第 i 个项目和对应分数的元组。将得分最高的前 K 个项目作为最终的推荐列表。

2.2 超图定义

超图允许一条超边连接多个顶点, 与普通图的边仅连接两个顶点的约束形成对比, 如图 1 所示。超图定义为 $G=(V^h, E^h)$, 其中顶点集 V^h 包含 N 个顶点 v , 超边集 E^h 包含 M 条超边 e , 并为每条超边都赋予正权重 $w_e > 0$, 使用对角矩阵 $\mathbf{W} \in \mathbf{R}^{M \times M}$ 存储 e 的权重。超图的关联矩阵 $\mathbf{H} \in \mathbf{R}^{N \times M}$ 定义如下: 当 $v \in V^h$, $e \in E^h$ 且 $v \in e$ 时, $h_{(v,e)}=1$, 否则 $h_{(v,e)}=0$ 。顶点的度由对角矩阵 $\mathbf{D} \in \mathbf{R}^{N \times N}$ 表示, 顶点 v 的度指与 v 相关联的超边 e 的权重之和, 为 $d_v = \sum_{e=1}^M w_e h_{(v,e)}$ 。超边的度由对角矩阵 $\mathbf{B} \in \mathbf{R}^{M \times M}$ 表示, 超边 e 的度指所连接的顶点 v 的数量, 为 $b_e = \sum_{v=1}^N h_{(v,e)}$ 。




图 1 普通图与超图对比

Fig. 1 Comparison of ordinary graph and hypergraph

2.3 社交超图定义

在超图的基础上, 进一步定义了社交超图, 社交超图是一种异构图, 其包含超边和社交边, 表示为 $G=(V^h, E^h, E^s)$, $E^s = \{e_s = \{u_i, u_j\} | u_i, u_j \in V^h, u_i \neq u_j\}$ 是社交边。

2.4 三元组模式定义

三元组模式是指图中由 3 个顶点及其相互之间的边构成的特定结构。对于投影图 $A=(V, E)$, 其中 $V=G$ 为群组集合, E 为边集合, 若 $(g_i, g_j) \in E \wedge (g_i, g_k) \in E \wedge (g_j, g_k) \in E$, 则 $\{g_i, g_j, g_k\}$ 构成一个三元组模式。在构建超图 $G=(V^h, E^h)$ 的过程时, 将其定义为一个超边 $e=\{g_i, g_j, g_k\} \in E^h$, 每条超边被赋予一个权重 w 表示这个模式的重要性, 如图 2 所示。




图 2 基于三元组的超图转换

Fig.2 Hypergraph transformation based on triadic motifs

3 算法设计

3.1 算法整体框架

针对当前群组推荐研究忽略组内和组间的高阶协作关系, 并存在数据稀疏性的问题, 本文设计了 HGRS 模型, 整体框架如图 3 所示, 包含双行为通道、自监督学习阶段、特征融合阶段、推荐预测阶段 4 个核心部分。




图 3 本文算法框架图

Fig. 3 Algorithm frame diagram of this paper

双行为通道：由用户级和群组级行为通道组成，分别学习群组内和群组间的高阶协作关系。用户级行为通道通过构建用户-项目超图与用户-用户社交图的异构图结构，同时捕捉组内多个用户与多个项目间的协同偏好与组外社交影响；群组级行为通道建模群组间高阶关系，通过三元组模式构建超图，学习群组间直接与间接高阶关系。

自监督学习阶段：为了缓解数据稀疏性的问题，通过定义正负样本对，构建对比学习任务，最大化用户级与群组级通道的互补信息，显著提升群组表示的完整性。

特征融合阶段：为了解决特征权重分配不合理的问题，使用门控机制自适应地学习双通道特征权重，动态调整各通道贡献度。

推荐预测阶段：利用特征融合阶段得到的群组表示，预测目标群组可能感兴趣的项目，最后生成推荐列表。

3.2 双行为通道

3.2.1 用户级行为通道

(1) 用户级超图构建

在群组推荐系统中，普通图仅能捕捉用户和项目间的简单关系，难以学习用户和项目间的高阶关系，本文构建了用户-项目超图，以超边形式聚合用户及其交互项目的信息。然而，用户的决策不仅受组内用户影响，而且受到社交网络中“意见领袖”的影响，传统超图仅建模组内交互，忽略了组外社交。为此本文引入社交关系，构建异构的社交超图 $G=(V^h, E^h, E^s)$ ，其中 $V^h=U$ 表示用户节点集， $E^s=\{e_s=\{u_i, u_j\} | u_i, u_j \in U, u_i \neq u_j\}$ 表示社交边集。对于群组 g_t 中的用户 u_m ，通过超边 $E_t^h=U_t \cup I_t$ 与组内其他用户和其交互项目相连，并通过社交边 $E_{u_m}^s$ 与组外的社交好友相连，如图 3 左侧成员级超图所示。

(2) 用户级超图卷积

利用超图卷积提取融合社交关系的用户表示以及项目特征，将用户嵌入 $\bar{U}$ 和项目嵌入 $\bar{I}$ 拼接为 $\mathbf{X}^{(0)}=[\bar{U}; \bar{I}]$ 并输入到 HGCN 中，定义为

$$\mathbf{X}^{(l+1)} = \mathbf{D}_u^{-1} \mathbf{H}_u \mathbf{W}_u \mathbf{B}_u^{-1} \mathbf{H}_u^T \mathbf{X}^{(l)} \mathbf{P}^{(l)} \quad (1)$$

其中： $\mathbf{X}^{(0)}$ 为第 l 层节点嵌入表示， $\mathbf{D}_u$ 为节点的度数的对角矩阵， $\mathbf{H}_u$ 为超图的关联矩阵， $\mathbf{W}_u$ 初始化为单位矩阵， $\mathbf{P}^{(0)}$ 为两个卷积层之间的可学习参数矩阵。

为了让组外社交影响有效融入用户表示中，每一层超图卷积计算完成后，在用户-用户社交图上引

入注意力聚合机制，利用该机制对超图卷积输出的用户表示进行更新，更新式为

$$\mathbf{u}_i^{(l+1)} = \mathbf{u}_i^{(l)} + \sum_{j \in N(i)} \alpha_j \mathbf{W}_1 \mathbf{u}_j^{(l)} \quad (2)$$

$$\alpha_j = \frac{\exp(\mathbf{h}_1^T \mathbf{W}_1 \mathbf{u}_j^{(l)})}{\sum_{j' \in N(i)} \exp(\mathbf{h}_1^T \mathbf{W}_1 \mathbf{u}_{j'}^{(l)})} \quad (3)$$

其中： $\mathbf{u}_i^{(l)}$ 为用户 u_i 在第 l 层节点嵌入向量， α_j 为用户 u_j 对用户 u_i 的社交关系重要性， $\mathbf{W}_1$ 和 $\mathbf{h}_1^T$ 为可学习参数， $N(i)$ 为用户 u_i 的社交好友集合。

最后，为了不丢失每层的输出信息，将每层获得的嵌入表示再使用平均策略进行划分，得到用户表示 $\mathbf{U}^*$ 和项目表示 $\mathbf{I}^*$ 。

(3) 用户级群组表示

由于每个用户在群组决策中的影响力不同，使用注意力机制对用户表示加权求和得到群组表示，为

$$\mathbf{g}_t^U = \sum_{u_i \in G_t} \mu_{ij} \mathbf{W}_2 \mathbf{u}_i^* \quad (4)$$

$$\mu_{ij} = \frac{\exp(\mathbf{h}_2^T \mathbf{W}_2 \mathbf{u}_i^*)}{\sum_{u_j \in G_t} \exp(\mathbf{h}_2^T \mathbf{W}_2 \mathbf{u}_j^*)} \quad (5)$$

其中： $\mathbf{u}_i^* \in \mathbf{U}^*$ 为第 i 个用户的嵌入向量； μ_{ij} 为用户 u_i 在群体决策中的权重， $\mathbf{W}_2$ 和 $\mathbf{h}_2^T$ 为可学习参数。

3.2.2 群组级行为通道

1) 群组级超图构建

现有的大多数模型都倾向于将用户级超图直接转换为投影图的方法，学习群组间的直接关系，而忽视了群组间的间接联系。采用三元组模式构建群组级超图，以识别并利用群组间的高阶关系，从而实现对群组间关系的全面表示。由于三元组模式能够增强社交社区同质性凝聚力^[19]，强化群组间的联系，并集中关注最有信息价值的群组关系，这对学习群组偏好非常有益。尽管四元组和五元组模式也可以捕捉更复杂的群组间关系，但在实际中难以找到足够多的群组组合支持模型学习，导致数据稀疏性问题更加严重。

将用户级超图映射为投影图，将群组超边转换为投影点。如果任意两条超边共用至少一个节点，则在投影图中他们之间存在一条边，采用三元组模式选择最相关的群组。若 3 个群组相互连接符合三元组模式，就将这 3 个群组定义为一个模式诱导的超边，群组级超图表示为 G_{gl} 。根据文献[20]的方法，在不考虑自连接的情况下，可用式 (6) 直接计算三元组模型的邻接矩阵，表示为 $\mathbf{H}_{gl} \mathbf{H}_{gl}^T$ 。

$$\mathbf{H}_{gl} \mathbf{H}_{gl}^T = (\mathbf{C}\mathbf{C}) \odot \mathbf{C} \quad (6)$$

其中: $\mathbf{H}_{gl} \in \mathbf{R}^{[G] \times [G]}$ 为群组级超图的三元组模式关联矩阵, $(\mathbf{H}_{gl} \mathbf{H}_{gl}^T)_{ij}$ 为顶点 i 和顶点 j 共同参与的超边数量, $\mathbf{C} \in \mathbf{R}^{[G] \times [G]}$ 为投影图的邻接关系。若群组 i 和群组 j 间存在连接, 则 $c_{ij}=1$, 否则 $c_{ij}=0$ 。 $\mathbf{C}\mathbf{C}$ 为连接 3 个顶点的路径, 而 $\odot \mathbf{C}$ 将这些路径转换成闭合的三角形。

基于群组间相似度, 为群组级超图的超边分配权重, 相似性高的群组将赋予更高的优先级, 指导模型关注更相关的群组关系, 从而提高推荐的准确性。权重的计算方式为

$$\text{sim}(g_i, g_j, g_k) = \frac{|U_i \cap U_j| + |U_j \cap U_k| + |U_i \cap U_k|}{|U_i \cup U_j \cup U_k|} \quad (7)$$

$$\omega_{i,j,k} = \frac{\text{sim}(g_i, g_j, g_k)}{\max(|U_i|, |U_j|, |U_k|)} \quad (8)$$

其中: 群组 g_i 、 g_j 、 g_k 的用户集分别为 U_i 、 U_j 、 U_k 。利用两两群组间的共同用户数量, 按照式 (7) 计算群组间相似度。为了确保权重值在 0~1 之间, 按照式 (8) 进行归一化处理, 归一化的相似度分数即为超边的权重。

2) 群组表示学习

群组级的超图卷积定义为

$$\mathbf{G}^{(l+1)} = \mathbf{D}_{gl}^{-1} \mathbf{H}_{gl} \mathbf{W}_{gl} \mathbf{H}_{gl}^T \mathbf{G}^{(l)} \mathbf{Y}^{(l)} \quad (9)$$

其中: $\mathbf{G}^{(l)}$ 为第 l 层的群组嵌入表示, $\mathbf{D}_{gl}$ 为群组节点的

度矩阵, $\mathbf{W}_{gl}$ 为超边权重矩阵, $\mathbf{H}_{gl} \mathbf{H}_{gl}^T$ 为由三元组模式诱导的邻接矩阵, $\mathbf{Y}^{(l)}$ 为两个卷积层间的可学习参数矩阵。经过 L 层超图卷积后, 对每层学习到的表示求平均, 得到群组表示 $\mathbf{G}^* = \frac{1}{L+1} \sum_{l=0}^L \mathbf{G}^{(l)}$, 那么第

t 个群组的群组表示为 $\mathbf{g}_t^G = \mathbf{G}_t^*$ 。

3.3 自监督学习

在用户级行为通道和群组级行为通道间进行自监督学习, 通过挖掘两通道的互补信息, 缓解数据稀疏的问题。用户级行为通道捕获用户-项目的高阶协作关系与用户的组外社交影响力, 构建细粒度的群组偏好表示; 群组级行为通道挖掘群体-群体间高阶关系建模群组共性偏好。用户级行为通道弥补了群组级通道在组内个体偏好差异性、决策权重分化及社交影响的刻画不足, 群组级行为通道则填补了用户级通道对群体间潜在关联、群体共性偏好的挖掘空白。当用户-项目交互数据稀疏时, 可借助群组

间的关联信息推断偏好, 当群组交互数据不足时, 用户与项目交互特征可提供有效补充。对比学习促使两通道吸收对方的互补信息, 且无需额外标注数据, 适用于数据稀疏的群组推荐。

在自监督学习中, 定义正样本对和负样本对。同一群组节点在两个通道中学习到的嵌入向量构成正样本对。负样本包含两部分, 一部分为当前通道内与目标群组无共享成员且交互项目相似度低于 0.1 的其余群组节点嵌入, 另一部分为另一通道内与目标群组无共享成员且交互项目相似度低于 0.1 的其余群组节点嵌入。损失函数为

$$L_{UG} = -\log \frac{\varphi(g_t^U, g_t^G)}{\varphi(g_t^U, g_t^G) + \sum_{j \neq i} (\varphi(g_t^U, g_{t_j}^U) + \varphi(g_t^U, g_{t_j}^G))} \quad (10)$$

其中: $\varphi(\cdot, \cdot) = \exp(\theta(\cdot)) / \tau$, τ 为温度系数。为了使两个通道的群体表示尽可能地接近, 定义 $\theta(\cdot) = s(h(g_1), h(g_2))$, 其中 $\theta(\cdot)$ 为用于计算分数的函数, $s(\cdot, \cdot)$ 计算余弦相似度, $h(\cdot)$ 为非线性投影, 由两层感知器实现, 用于提高表示的质量^[21]。由于任意两个通道间都是对称的, 因此 L_{GU} 的计算方式与式 (10) 相同。最后, 平均两个通道间的对比损失, 得到最终的损失函数, 为

$$L_{ssl} = \frac{1}{2N} \sum_{i=1}^N (L_{UG} + L_{GU}) \quad (11)$$

3.4 特征融合

在两个通道中分别提取对应的群组表示, 引入神经门控机制整合这两个通道得到的群组表示, 生成最终的群组嵌入。门控机制通过学习不同特征的权重, 自适应地调整两个通道在最终表示中的相对贡献。门控融合过程为

$$r = \text{sigmoid}(\mathbf{Q}_a \mathbf{g}_t^U + \mathbf{Q}_b \mathbf{g}_t^G + \mathbf{b}) \quad (12)$$

$$\mathbf{g}_t = r \odot \mathbf{g}_t^U + (1-r) \odot \mathbf{g}_t^G \quad (13)$$

其中: $\mathbf{Q}_a$ 和 $\mathbf{Q}_b$ 为可训练的权重矩阵; $\mathbf{b}$ 为偏置项; r 为通过 Sigmoid 函数计算得到的门控权重值, 它决定了用户级表示 $\mathbf{g}_t^U$ 和群组级表示 $\mathbf{g}_t^G$ 在融合过程中的相对重要性。通过逐元素乘法 ($\odot$) 操作, 实现两种表示的加权融合, 得到最终的群组表示 $\mathbf{g}_t$ 。

3.5 推荐预测

在预测层中, 对于每个群组-项目对 $(\mathbf{g}_t, i_j)$, 将群组表示 $\mathbf{g}_t$ 与项目表示 i_j 进行乘法操作, 并与各自的独立表示进行拼接, 以融合群组和项目的交互信息。然后, 计算群组 $\mathbf{g}_t$ 对项目 i_j 的预测分数 $\hat{y}_{ij}$,

根据预测分数, 为每个群组生成推荐列表, 为

$$\hat{y}_{ij} = \mathbf{w}^T (\mathbf{W}_p [\mathbf{g}_i \odot \mathbf{i}_j; \mathbf{g}_i; \mathbf{i}_j] + \mathbf{b}_p) \quad (14)$$

其中: $\mathbf{w}^T$ 为预测层的权重向量, $\mathbf{W}_p$ 和 $\mathbf{b}_p$ 分别为权重矩阵和偏置向量。

在优化层中, 采用成对学习的任务损失函数训练群组 and 项目的表示, 最后将推荐任务和自监督学习任务结合起来进行联合训练, 为

$$L_{main} = \sum_{t, j, j' \in D_G} (\hat{y}_{tj} - \hat{y}_{tj'} - 1)^2 \quad (15)$$

$$L = L_{main} + \lambda L_{ssl} \quad (16)$$

其中: D_G 为群组-项目的训练集; (t, j, j') 为三元组样

表 1 预处理后的数据集信息

Tab. 1 Statistical information of experiment datasets

数据集	用户数	群组数	项目数	群组交互数	用户交互数	平均度	稀疏度
Mafengwo	5275	995	1513	3595	39761	3.61	0.998
CAMRa2011	602	290	7710	145068	116344	500.23	0.935

4.2 对比模型和评价指标

将 HGRS 模型与基准模型进行比较, 结果见表 2, 其中 HCR、ConsRec、HGRec 均采用了 HGCN, 由此验证 HGRS 模型使用双通道超图卷积的有效性。

本, 表示群组 g_i 与项目 i_j 进行了交互, 但与项目 $i_{j'}$ 未进行交互; λ 为控制自监督任务规模的参数。

4 实验与结果分析

4.1 数据集

为了验证 HGRS 模型的有效性, 在数据集 Mafengwo 和 CAMRa2011 上进行实验。在数据预处理阶段, 过滤去除未加入群组的用户, 保留至少加入 1 个群组的用户, 保留至少存在 2 名用户和至少存在 3 次项目交互的群组。将所有组按照 7 : 3 划分为训练集和测试集, 预处理后的数据集信息见表 1。

HGRec 和 HyperGroup 都提出了解决数据稀疏性问题的方法, 从而验证本文使用自监督学习的效果。GLIF、CubeRec、GEDA、Group-GF 为近年具有代表性的群组推荐模型。

表 2 不同模型在两个数据集上的性能比较

Tab.2 Comparison of performance among different models on two datasets

模型	Mafengwo 数据集				CAMRa2011 数据集			
	HR@5	HR@10	NDCG@5	NDCG@10	HR@5	HR@10	NDCG@5	NDCG@10
HCR	0.7668	0.8392	0.6644	0.6881	0.6022	0.8103	0.4057	0.4468
GLIF	0.7961	0.8763	0.7030	0.7163	0.5918	0.7893	0.4030	0.4673
HyperGroup	0.5681	0.6490	0.4652	0.4801	0.5779	0.802	0.3814	0.4490
CubeRec	0.8755	0.9103	0.7577	0.7723	0.6409	0.8210	0.4337	0.4928
ConsRec	0.8844	0.9156	0.7692	0.7794	0.6407	0.8248	0.4358	0.4945
GEDA	0.8060	0.8704	0.6993	0.7266	0.6208	0.7945	0.4203	0.4785
HGRec	0.8573	0.8884	0.7572	0.7674	0.6959	0.8248	<u>0.6391</u>	<u>0.6805</u>
Group-GF	<u>0.9014</u>	<u>0.9150</u>	<u>0.8102</u>	<u>0.8286</u>	<u>0.8016</u>	0.9218	0.4873	0.4991
HGRS	0.9126	0.9265	0.9099	0.9131	0.812	<u>0.8519</u>	0.6651	0.7038
p	0.031	0.027	0.002	0.003	0.041	0.035	0.038	0.029

注: 加粗的数据和有下列划线的数据分别为该指标的最优模型结果和次优模型结果。

HCR^[12]: 通过 HGCN 学习群组整体偏好, 与二部图学习个体偏好相结合进行群组推荐。

ConsRec^[22]: 采用改进的 HGCN 融合用户信息, 通过 3 个视图学习群组偏好, 进而获得更精准的群组特征。

HGRec^[23]: 通过超图表示的高阶偏好提取视图, 由重叠图表示的一致性偏好提取视图以及由二分图

表示的传统偏好提取视图形成群组偏好, 然后通过跨视图对比学习, 缓解数据稀疏。

HyperGroup^[14]: 引入分层超边嵌入策略, 逐层提取群组偏好, 同时引入好友偏好, 缓解用户-项目交互的数据稀疏。

GLIF^[24]: 从全局视图和局部视图学习群组偏好, 使用注意力机制将这两个视图的表征信息融合起

来, 形成最终的群组表示。

CubeRec^[13]: 引入超立方体空间进行群组推荐, 提供一种新的视角, 能够更好地建模和理解用户与项目之间的关系。

GEDA^[25]: 采用 NGCF (neural graph collaborative filtering) 模型^[26]获取用户和项目之间高阶交互信息, 再借助多注意力模块动态学习用户的决策权重, 更准确地把个体偏好聚合为群体偏好, 提升推荐效果。

Group-GF^[27]: 构建 3 种物品相似图, 为每种图设计最优的多项式图滤波器, 精准捕捉不同视角下的频率特征, 实现无需训练即可完成群组推荐。

本文将命中率 (hit ratio, HR)^[28]和归一化折损累积增益 (normalized discounted cumulative gain, NDCG)^[29]作为 HGRS 模型的评价指标。HR@K 用于衡量在推荐列表的前 K 个项目中实际命中 (预测正确) 的项目数量, NDCG@K 用于评估推荐列表中项目排序的准确性。NDCG 越大, 用户感兴趣的项目排得越靠前, 排序越准确。

为验证性能提升的可靠性, 采用双尾 t 检验对 HGRS 与次优模型的性能差异进行验证 (显著性水平 $\alpha=0.05$)。若 $p<0.05$, 则认为模型间性能差异具有统计显著性; 反之, 则认为差异由随机因素导致。所有实验均独立重复 10 次, 以确保结果的稳定性。

4.3 实验设置

HGRS 模型是在 Intel Core i9-14900KF CPU 以及 NVIDIA RTX 3090 GPU 的硬件平台基础上, 采用 Python 3.10 和 PyTorch 2.5.1 框架实现。嵌入层采用 Xavier 策略初始化节点的表示, 使用 Adam 优化器优化模型参数。设置 dropout 为 0.1, 学习率为 0.0001, 嵌入维度为 32, 批量大小为 512, 卷积层为 2, 负样本为 10, 控制自监督任务的超参数 λ 为 0.2。

4.4 性能比较

由表 2 可知: 在两个数据集上, HGRS 模型的各项性能指标均显著优于 3 个同样采用超图的模型 (HCR、ConsRec、HGRec)。与次优模型相比, 在 Mafengwo 数据集上, HR@5 和 HR@10 分别提升 1.12%、1.15%, NDCG@5 和 NDCG@10 分别提升 9.97%、8.45%; 在 CAMRa2011 数据集上, HR@5 提升了 1.04%, NDCG@5 和 NDCG@10 分别提升 2.6%、2.33%, 各指标的提升均具有统计显著性 ($p<0.05$)。这表明 HGRS 使用双通道超图卷积网络在捕捉组内和组间高阶信息的有效性。

HGRec 和 HyperGroup 都对数据稀疏性问题提出

了解决方案, 但 HGRS 模型引入自监督学习机制表现更为出色, 这也验证了在群组推荐模型中引入自监督学习的必要性。

在 CAMRa2011 数据集上, HGRS 模型的 HR@10 略低于 Group-GF 模型, 且差异具有统计显著性。该数据集平均群组大小仅为 2.08, 单一群组内仅包含 2 名用户, 组内用户交互行为呈现简单的二元关系, 难以形成复杂的多节点高阶交互模式。同时, 小群组的结构特性导致群组间的重叠度低, 无法形成有效的三元组模式高阶关联, 群组间的高阶协作关系特征极不显著, 在此数据集上难以充分发挥作用。Group-GF 采用轻量级无训练的多视图图滤波设计, 无需建模复杂的高阶关系, 仅通过聚合群组的直接交互偏好即可完成推荐, 更适配 CAMRa2011 数据集的简单交互特征, 因此在 HR@10 指标上表现更优。

4.5 消融实验

为了验证 HGRS 模型各个组件的有效性, 在 Mafengwo 数据集上将以下变体模型与 HGRS 整体模型进行对比, 结果见表 3, 其中 HGRS-mh 模型移除用户级行为通道, HGRS-gh 模型移除群组级行为通道, HGRS-ssl 模型移除自监督学习, HGRS-gate 模型移除门控机制, 使用特征相加得到最终群组表示。

表 3 HGRS 模型的消融实验结果

Tab. 3 Ablation experiment results among HGRS models

模型	HR@5	HR@10	NDCG@5	NDCG@10
HGRS-mh	0.8372	0.8417	0.8318	0.8367
HGRS-gh	0.8578	0.8635	0.8617	0.8473
HGRS-ssl	0.8924	0.9073	0.8873	0.8908
HGRS-gate	0.8976	0.9149	0.8965	0.9074
HGRS	0.9126	0.9265	0.9099	0.9131

由表 3 的消融实验结果可知, 各模块移除后均会导致模型不同程度的性能衰减。

(1) HGRS-mh 移除用户级行为通道后, HR@5 和 NDCG@5 分别下降了 7.54% 和 7.81%, 模型性能跌幅最大。原因在于模型同时失去用户-项目超图与用户-用户社交图的双重信号, 组内高阶偏好与组外社交影响均无法建模, 致使群组表示缺乏用户级细粒度表示, 只能依赖群级通道提供的群体-群体的粗粒度信息。

(2) HGRS-gh 移除了群组级行为通道, HR@5 和 NDCG@5 分别下降了 5.48% 和 4.82%, 模型性能跌幅明显。由于该通道对群组间的相似性、互动模式以及群组间的高阶关系进行了建模, 这对增强群

组表示十分重要。

(3) HGRS-ssl 移除跨通道自监督学习后, 用户级与群组级两个通道各自独立优化, 表征空间逐渐偏离, 缺乏互补信号缓解数据稀疏。

(4) HGRS-gate 将门控融合简化为相加后, 模型无法自适应调节通道权重, 导致小规模群组噪声放大, 大规模群组结构信息被弱化, 影响整体性能。

4.6 参数分析

分析超参数对 HGRS 模型性能的影响, 卷积层数从{1,2,3,4,5}中取值, 嵌入维度从{16,32,64,96,128}中取值, 批量大小从{64,128,256,512,1024}中取值, 负样本数量从{6,8,10,12,14}中取值。

在 Mafengwo 和 CAMRa2011 数据集上, 不同卷积层数下 HGRS 的性能如图 4 所示。当 HGRS 模型的卷积层数为 2 时, 模型在两个数据集上的性能均达到峰值。随着卷积层数的增加, 会逐渐出现过平滑现象, 使不同节点的特征表示逐渐趋同, 导致模型性能显著下降。




图 4 不同层数下 HGRS 模型的性能

Fig. 4 Performance of HGRS model with different layers

在 Mafengwo 和 CAMRa2011 数据集上, 不同嵌入维度 HGRS 模型的性能如图 5 所示。随着嵌入维度的增加, HGRS 模型的性能呈现先升后降的趋势。当嵌入维度超过 32 后, 性能开始下降, 这是因为模型开始过度拟合数据, 导致性能变差。

在 Mafengwo 和 CAMRa2011 数据集上, 不同批

量大小下 HGRS 模型的性能如图 6 所示。当批量大小设置为 512 时, HGRS 模型的性能在两个数据集上均达到最佳状态。当批量大小较小时, 不足以提供足够的数据更新模型参数, 导致模型学习不稳定; 当批量大小过大时, 模型可能会过拟合于特定的数据批次, 导致泛化能力变弱, 推荐性能受到影响。




图 5 不同维度下 HGRS 模型的性能

Fig. 5 Performance of HGRS model with different dimensions




图 6 不同批量大小下 HGRS 模型的性能

Fig. 6 Performance of HGRS model with different batch

sizes

在 Mafengwo 和 CAMRa2011 数据集上, 不同负样本数量下 HGRS 模型的性能如图 7 所示。当推荐预测任务的负样本数量为 10 时, HGRS 模型性能达到最佳, 当偏离这个值时, 性能均在下降。这是因为当负样本数量不足时, 没有足够的信息进行学习, 使模型的性能变差; 当负样本数量过多时会引入噪声, 干扰模型正常学习, 使推荐质量下降。




图 7 不同负样本下 HGRS 模型的性能

Fig.7 Performance of HGRS model with different negatives

5 结 语

本研究充分利用组内和组间的高阶协作关系, 提出跨通道自监督增强的超图群组推荐模型 (HGRS)。在用户级行为通道中, 构建用户-项目超图与用户-用户社交图的异构图结构, 同时捕捉组内多个用户与多个项目间的协同偏好与组外社交影响。在群组级行为通道中, 基于三元组模式重新构建群组级超图, 从而学习群组-群组的高阶交互关系。针对数据稀疏性问题, 将自监督学习技术整合到模型中, 在两个通道间建立互补的信息流, 增强群组表示。在两个真实数据集上进行实验, 结果表明 HGRS 模型在 HR 和 NDCG 上均优于其他模型。

尽管 HGRS 模型在静态图结构中表现出色, 但用户行为和群组交互会随时间动态变化, 静态建模难以捕捉动态特征, 下一步的研究工作将引入动态图神经网络, 实时更新群组表示, 进一步提升群组

推荐的性能。

参考文献:

- [1] Singhal S, Pal K. State of art and emerging trends on group recommender system: a comprehensive review[J]. International Journal of Multimedia Information Retrieval, 2024, 13(22): 1- 39.
- [2] Sato R. Enumerating fair packages for group recommendations[C]// Proceedings of the 15th ACM International Conference on Web Search and Data Mining. New York: ACM, 2022: 870-878.
- [3] 郑楠, 章颂, 刘玉桥, 等. 基于深度学习的群组推荐方法研究综述[J]. 自动化学报, 2024, 50(12): 1000- 1023.
- [4] Liu Xingjie, Tian Yuan, Ye Mao, et al. Exploring personal impact for group recommendation[C]// Proceedings of the 21st ACM International Conference on Information and Knowledge Management. Maui: ACM, 2012: 674-683.
- [5] Yuan Quan, Cong Gao, Lin C Y. COM: a generative model for group recommendation[C]// Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 163-172.
- [6] Cao Da, He Xiangnan, Miao Lianhai, et al. Attentive group recommendation[C]// Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. Ann Arbor: ACM, 2018: 645-654.
- [7] Deng Zhiyi, Li Changyu, Liu Shujin, et al. Knowledge-aware group representation learning for group recommendation[C]// Proceedings of the 37th International Conference on Data Engineering. Chania: IEEE, 2021: 1571-1582.
- [8] Zhang Song, Zheng Nan, Wang Danli. HetGRec: heterogeneous graph attention network for group recommendation[J]. IEEE Intelligent Systems, 2023, 38(1): 9-18.
- [9] Leng Y F, Yu Li. Incorporating global and local social networks for group recommendations[J]. Pattern Recognition, 2022, 127: 108601.
- [10] Hong Tao, Ibrahim N F. Group recommendation fueled by noise-based graph contrastive learning[J]. Journal of King Saud University-Computer and Information Sciences, 2024, 36: 102063.
- [11] Zhou Chenyang, Zou Guobing, Hu Shengxiang, et al.

- Dual-graph convolutional network and dual-view fusion for group recommendation[J]. *Lecture Notes in Computer Science*, 2024, 14649: 231-243.
- [12] Jia Renqi, Zhou Xiaofei, Dong Linhua, et al. Hypergraph convolutional network for group recommendation[C]// 2021 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE, 2021: 260-269.
- [13] Chen Tong, Yin Hongzhi, Long Jing, et al. Thinking inside the box: learning hypercube representations for group recommendation[C]// Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 1664-1673.
- [14] Guo Lei, Yin Hongzhi, Chen Tong, et al. Hierarchical hyperedge embedding-based representation learning for group recommendation[J]. *ACM Transactions on Information Systems*, 2022, 40(1): 1-27.
- [15] 王聪, 史艳翠. 基于多视角学习的图神经网络群组推荐模型[J]. *计算机应用*, 2025, 45(4): 1205-1212.
- [16] Li Yunxi, Xing Xing, Liu Yiqi, et al. Session-based recommendation of self-supervised hypergraph convolutional networks incorporating self-attention[C]// Proceedings of the 2024 IEEE 13th Data Driven Control and Learning Systems Conference. Piscataway: IEEE, 2024: 358-363.
- [17] Wei Feng, Chen Shuyu. Multi-view collaborative training and self-supervised learning for group recommendation[J]. *Mathematics*. 2025, 13(1): 66-87.
- [18] Li Kang, Wang Changdong, Lai Jianhuang, et al. Self-supervised group graph collaborative filtering for group recommendation[C]// Proceedings of the 16th ACM International Conference on Web Search and Data Mining (WSDM 2023). New York: ACM, 2023: 69-77.
- [19] Lee G, Ko J, Shin K. Hypergraph motifs: concepts, algorithms, and discoveries[J]. *Proc. VLDB Endow.*, 2020, 13, 11: 2256-2269.
- [20] Zhao Huan, Xu Xiaogang, Song Yangqiu, et al. Ranking users in social networks with motif-based pagerank[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 33(5): 2179-2192.
- [21] Chen Ting, Kornblith S, Norouzi M, et al. A simple framework for contrastive learning of visual representations[C]// Proceedings of the 37th International Conference on Machine Learning. New York: PMLR, 2020: 1597-1607.
- [22] Wu Xixi, Xiong Yuan, Zhang Yao, et al. ConsRec: learning consensus behind interactions for group recommendation[C]// Proceedings of the ACM Web Conference. New York: ACM, 2023: 240-250.
- [23] Wang Nan, Liu Dan, Zeng Jin, et al. HGRec: group recommendation with hypergraph convolutional networks[J]. *IEEE Transactions on Computational Social Systems*, 2024, 11(3): 4214-4225.
- [24] Zhang Song, Zheng Nan, Wang Danli. A novel attention-based global and local information fusion neural network for group recommendation[J]. *Machine Intelligence Research*, 2022, 19(4): 331-346.
- [25] Yu Li, Leng Youfang, Zhang Dongsong, et al. Collaborative group embedding and decision aggregation based on attentive influence of individual members: a group recommendation perspective[J]. *Decision Support Systems*, 2023, 165: 113894.
- [26] 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.
- [27] Kim C H, Choi Y R, Park J D, et al. Leveraging member-group relations via multi-view graph filtering for effective group recommendation[C]// Companion Proceedings of the ACM Web Conference 2025. Sydney: ACM, 2025: 1077-1081.
- [28] Shi Chuan, Han Xiaotian, Song Li, et al. Deep collaborative filtering with multiaspect information in heterogeneous networks[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 33(4): 1413-1425.
- [29] He Ruining, McAuley J. Ups and downs: modeling the visual evolution of fashion trends with one-class collaborative filtering[C]// Proceedings of the 25th International Conference on World Wide Web. Republic and Canton of Geneva: International World Wide Web Conferences Steering Committee, 2016: 507-517.