ConsRec：学习群体推荐中交互背后的共识

Xixi Wu
21210240043@m.fudan.edu.cn
上海市数据科学重点实验室
计算机科学学院
复旦大学计算机科学学院
大学
中国上海

Yun Xiong*
yunx@fudan.edu.cn
上海市数据科学重点实验室
数据科学，学院的
复旦大学计算机科学
大学
中国上海

Yao Zhang
yaozhang@fudan.edu.cn
上海重点实验室
数据科学系，
计算机科学学院，复旦
大学
中国上海

Yizhu Jiao
yizhuj2@illinois.edu
伊利诺伊大学
厄巴纳-香槟分校
伊利诺伊
州，美国

Jiawei Zhang
jiawei@ifmlab.org
IFM实验室，
计算机科学，
加利福尼亚州大学，
戴维斯
加利福尼亚
州，美国

Yangyong Zhu
yyzhu@fudan.edu.cn
上海市数据科学重点实验室
，计算机科学学院
，复旦
大学
中国上海

Philip S. Yu
psyu@uic.edu
伊利诺伊大学
芝加哥
伊利诺伊
州，美国

arXiv:2302.03555v1 [cs.IR] 7 Feb 2023

摘要

随着群体活动在日常生活中日益普遍，为一群用户生成推荐的需求也变得十分迫切，这一任务称为群组推荐。现有群组推荐方法通常通过聚合不同成员的兴趣来推断群体偏好。实际上，群组的最终选择涉及成员之间的妥协，最终达成共识。然而，现有的个体信息聚合缺乏全面的群组级考量，无法捕捉共识信息。此外，其具体的聚合策略要么计算成本高昂，要么粒度过于粗略，难以做出精准预测。

为解决上述局限性，本文聚焦于探索群体行为数据背后的共识。为全面捕捉群体共识，我们创新性地设计了三个相互补充、能够支持多视图学习的不同视图，分别是成员级聚合、物品级偏好和群组层级内在偏好。为整合并平衡多视图信息，我们进一步提出了一种自适应融合组件。对于成员级聚合，不同于现有的线性或注意力策略，我们设计了一种新颖的超图神经网络，可高效执行超图卷积运算，从而生成具有丰富表达能力的成员级聚合。我们在两个真实世界数据集上评估了 ConsRec，实验结果表明，我们的模型优于最先进的方法。此外，广泛的案例研究也验证了共识建模的有效性。

CCS 概念

• **信息系统** → **推荐系统**；• **计算方法** →**神经网络**。

关键词

群组推荐、图表示学习、数据挖掘

ACM参考文献格式：

Xixi Wu、Yun Xiong、Yao Zhang、Yizhu Jiao、Jiawei Zhang、Yangyong Zhu 和 Philip S. Yu。2023年。ConsRec：学习群体推荐中交互背后的共识。载于 *ACM*网络会议论文集*2023*（*WWW '23*），*2023*年*5*月*1*日至*5*日，美国德克萨斯州奥斯汀。ACM，美国纽约州纽约市，11页。
https://doi.org/10.1145/3543507.3583277

1 引言

由于社交媒体的普及， [24, 25], 在线群组活动已经变得十分常见。现有的各种在线社交媒体网站都可以为用户提供与群组相关的服务。例如，旅游爱好者可以在马蜂窝[1]上规划群体旅行，年轻人也可以在Meetup[2]上组织群体聚会。由于传统推荐方法仅针对个人推荐相关物品，因此，迫切需要为一组用户生成推荐，这被称为群组推荐任务 [4, 5]。形式上，群组推荐旨在促使群组成员达成共识，以提供能够满足大多数成员需求的内容 [39]。

以往关于群体推荐的研究 [1–6, 11, 12, 15, 16, 20, 29–31, 38, 39] 通常侧重于聚合多样化成员的偏好，以预测群组兴趣。传统的聚合方法基于预先定义的启发式规则，包括平均值 [3],

*通讯作者

允许免费制作本作品全部或部分内容的数字或纸质副本，供个人或课堂使用，前提是不得为营利或商业目的制作或分发副本，且副本首页须包含本声明和完整引文。本作品中归属 ACM 以外其他方所有的组件，其版权必须得到尊重。注明出处后允许摘录。若要以其他方式复制、重新发表、发布到服务器或重新分发至列表，则须事先获得具体许可和/或支付费用。请通过 permissions@acm.org 申请许可。*WWW '23*，*2023*年*5*月*1*日至*5*日，美国德克萨斯州奥斯汀© 2023 计算机协会。ACM ISBN 978-1-4503-9416-1/23/04...$15.00 https://doi.org/10.1145/3543507.3583277

[1]https://www.mafengwo.cn[2]https://www.meetup.com

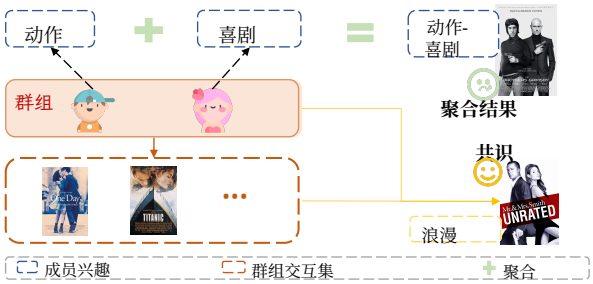


图1：聚合结果与群组共识之间差距的示例。仅仅聚合多样化的成员兴趣，缺乏对群组整体品味的全面考量，因而无法捕捉共识。

最小痛苦 [1], 和最大满意度 [2]。此外，还有一些深度学习模型 [4, 5, 12, 15, 31]利用注意力机制实现可学习的聚合。近期，CubeRec [6] 利用超立方体 [26, 40] 的几何表达能力，聚合成员多方面的偏好，取得了最先进的性能。

尽管现有方法具有一定效果，我们认为当前的群体推荐方法在建模以下两个因素方面仍存在不足：（1）**共识**。一个重要事实被忽视了：群组的最终选择涉及成员之间的妥协，最终需要达成一致意见 [6, 12]。共识驱动群组作出最终决策，而现有的个体信息聚合缺乏群体层面的整体考量，因而无法捕捉共识。以图1为例，该群组由一对情侣组成，其中男士偏好动作片，而女士喜欢喜剧片。当他们计划一起观看电影时，共识可能是一部浪漫电影，而不是聚合后的动作喜剧片。在现实场景中，这类情况十分常见，但在上述方法中却基本未得到关注。（2）**成员级聚合**。一种典型的群组兴趣聚合策略是注意力机制 [4, 5, 12, 15, 16, 31] ，该机制会为不同的候选物品计算不同的注意力权重。考虑到现实场景中数量庞大的候选产品，这类方法很难实际应用。此外，由于交互频繁的成员更有可能获得较高的注意力权重 [23]，这种方法往往偏向这些成员。尽管 CubeRec [6] 采用超立方体寻求更好的解决方案，但由于成员兴趣的多样性，所得超立方体可能过大，从而难以进行精确预测。因此，还需要一种兼顾效率与效果的适当聚合策略。

本文聚焦于探索群组-物品交互和用户-物品交互背后的群体共识，以提升推荐的性能和意义。我们提出一种新模型 **ConsRec**，以相应地解决上述局限：（1）**群体共识建模**。为全面捕捉群体共识，我们创新性地设计了三个不同的视图，提供互补信息。除了为群体共识提供细粒度解释的成员级视图外，我们认为，有时也可以从交互物品的特征中捕捉群组的共识，作为，以及它们的固有属性。例如，由家庭成员组成的群组更倾向于观看家庭喜剧。因此，我们提出了新颖的物品级视图和群体级视图，分别用于获取群组的物品级偏好和固有兴趣。对于每个数据视图，我们设计了特定的图结构来编码行为数据，并利用图表示学习技术生成群组的表示。为了整合和平衡多视图信息，我们进一步提出了自适应融合组件，以合成最终的群体共识。在优化过程中，推荐预测可以监督学习过程，自适应地调整不同视图的贡献，从而提取最具判别性的共识信息。（2）**有效的成员级聚合**。我们提出了一种新颖的超图学习架构，用于获取成员级聚合。与现有的注意力聚合相比，我们的方案通过超图卷积操作获取聚合结果，在效率方面更具优势；通过设计有意义的侧信息来平衡对部分成员的偏向，在公平性方面更具优势；通过融入高阶协同信息，在表达能力方面更具优势。在两个公开数据集上的大量实验表明，我们提出的方法不仅有效，而且高效。

To 总结而言，我们的工作贡献如下 ：

- 我们研究群组推荐任务，并揭示群组决策背后的共识。为全面捕捉共识，我们设计了三个新颖且互补的视图，包括成员级聚合、物品级偏好和群组固有兴趣。
- 我们提出了一种新颖的超图神经网络，用于实现成员级聚合。与现有的注意力聚合方法相比，我们的方法在效率、公平性和表达能力方面更具优势。
- 在两个公开数据集上进行的大量实验表明，我们提出的方法既有效又高效。

2 相关工作

2.1 偏好聚合

现有群组推荐技术通常采用聚合策略：首先从用户-物品交互中学习成员的偏好，然后执行偏好聚合，以推断群组的整体兴趣 [6]。有时，群组的最终选择由群组级共识决定。然而，现有方法缺乏对群组整体品味的全面考量，因而无法捕捉共识。

2.1.1 评分聚合。这类方法会生成群组中所有成员对某个候选物品的评分，然后通过一些手工设计的启发式规则聚合个体评分，以获得群组的偏好评分，例如平均值 [3], 、最小痛苦 [1], 和最大满意度 [2]。例如，平均值 [3] 策略将成员评分的平均值作为最终推荐评分。尽管直观，这些预定义的聚合规则却难以灵活反映成员的多样化意图 [16]。

2.1.2 神经聚合。 为了获得更好的性能，一些研究人员提出以可学习的方式聚合不同成员的意图 [4–6, 12, 15, 30, 31, 38]。具体而言，这些方法首先根据用户

交互将每个成员表示为一个隐式嵌入，然后使用学习到的权重对所有成员的嵌入求和，从而计算群组嵌入。例如，文献 [4] 提出了注意力神经网络，以选择性地聚合群组内的用户表示；[31] 进一步通过子注意力网络捕捉群组成员之间的细粒度交互。最近，CubeRec [6] 利用超立方体的几何表达能力，自适应地聚合多方面用户偏好，从而取得了更好的性能。

2.2 近期方向

为实现更好的群组画像，近期的群体推荐研究采用了更复杂的结构，例如超图 [11, 16, 39] 和超立方体 [6]。此外，研究也采用了自监督学习技术来缓解数据稀疏问题 [29, 39]。

2.2.1 超图学习。 超图是一种更通用、能够保留元组级关系的拓扑结构，因此天然适用于群组画像。因此，近期研究 [11, 16, 39]将群组表示为超边，并采用超图神经网络生成表达能力更强的向量。我们指出，这些方法主要利用超图结构传播用户级协同信号，并全面采用注意力聚合 [32] 进行群组级预测。事实上，超图网络能够更高效地实现富有表现力的成员级聚合，但这些方法忽略了这一点。

2.2.2 自监督学习。鉴于自监督学习（SSL）已在通用推荐任务中展现出有效性 [35, 37,41], ，研究者也尝试设计自监督学习目标，以缓解群组推荐任务中的数据稀疏性问题 [6, 29, 39]。例如，GroupIM [29] 提出了一种用户-群组互信息最大化方案，以联合学习具有丰富信息的用户和群组表示。

3 预备知识

本节将介绍群组推荐任务的定义以及超图的相关概念，以便于理解。具体而言，我们用粗体大写字母（例如，$\mathbf{X}$）和粗体小写字母（例如，$\mathbf{x}$）分别表示矩阵和向量。我们用非粗体字母（例如，x）表示标量，用花体字母（例如，$\mathcal{X}$）表示集合。符号汇总于附录中的表6。

3.1 任务定义

令 $\mathcal{U} = \{u_1, u_2, ..., u_M\}$、$\mathcal{I} = \{i_1, i_2, ..., i_N\}$ 和 $\mathcal{G} = \{g_1, g_2, ..., g_K\}$ 分别表示用户、物品和群组的集合，其中 M、N 和 K 分别表示这三个集合的大小。$\mathcal{U}$、$\mathcal{I}$ 和 $\mathcal{G}$ 之间存在两种已观测交互，即群组-物品交互和用户-物品交互。我们用 $\mathbf{Y} \in \mathbb{R}^{K \times N}$ 表示群组-物品交互；若群组 g_t 与物品 i_j 发生交互，则元素 $\mathbf{Y}(t, j) = 1$，否则 $\mathbf{Y}(t, j) = 0$。同理，我们用 $\mathbf{R} \in \mathbb{R}^{M \times N}$ 表示用户-物品交互。$\mathcal{G}$ 中第 t 个群组 $g_t \in \mathcal{G}$ 由一组用户成员组成：$\mathcal{G}_t = \{u_1, u_2, ..., u_s, ..., u_{|\mathcal{G}_t|}\}$，其中 $u_s \in \mathcal{U}$，且 $|\mathcal{G}_t|$ 表示 $\mathcal{G}_t$ 的大小。我们将 g_t 的交互集表示为 $\mathcal{Y}_t = \{i_1, i_2, ..., i_j, ..., i_{|\mathcal{Y}_t|}\}$，其中 $i_j \in \mathcal{I}$，且 $|\mathcal{Y}_t|$ 表示 $\mathcal{Y}_t$ 的大小。给定目标群组 g_t 后，群组推荐任务定义为向其推荐可能感兴趣的物品 g_t。

3.2 超图

与简单图不同，超图是一种更一般的拓扑结构，其中边（即超图中的超边）可以连接两个或更多节点 [7, 33, 37]。形式上，我们将超图定义为 $G = (\mathcal{V}, \mathcal{E}, \mathbf{H})$，其中 $\mathcal{V}$ 为顶点集，$\mathcal{E}$ 为超边集，$\mathbf{H} \in \mathbb{R}^{|\mathcal{V}| \times |\mathcal{E}|}$ 表示超图的连通关系：若超边 e 连接顶点 v，则 $\mathbf{H}(v, e) = 1$；否则 $\mathbf{H}(v, e) = 0$。在此基础上，我们进一步给出 G 中的一些记号。令 $\mathcal{E}_v$ 表示与节点 v 相连的一组相关超边（*i.e.*，$\mathcal{E}_v = \{e \in \mathcal{E} | \mathbf{H}(v, e) = 1\}$），并令 $\mathcal{V}_e$ 表示超边 e 所连接的一组节点（即 $\mathcal{V}_e = \{v \in \mathcal{V} | \mathbf{H}(v, e) = 1\}$）。

4 方法

本节首先详细阐述群体共识的多视图建模。随后，我们介绍由图神经网络增强的具体编码过程。接着，我们介绍用于整合多视图信息的自适应融合机制。最后，我们展示所采用的优化方法。ConsRec 的整体架构如图2所示。本节使用的符号也汇总于附录中的表6。

4.1 共识的多视图建模

为了有效利用群体行为数据来捕捉群体共识，我们设计了三种新颖的视图，它们提供互补信息以支持多视图学习。图2左侧展示了示意图。

4.1.1 成员级。由于群组由多样化的成员组成，我们首先从成员构成视图分析每个群组，该视图为群体决策提供细粒度的解释。然而，传统图结构仅支持反映一对一关系的成对关系。因此，我们提出用超图对群组与成员之间的元组关系进行建模。形式上，我们使用超图 $G^m = (\mathcal{V}^m, \mathcal{E}^m, \mathbf{H}^m)$构建成员视图，其中 $\mathcal{V}^m = \mathcal{U} \cup \mathcal{I}$ 表示节点集，$\mathcal{E}^m = \mathcal{G}$ 表示超边集，邻接矩阵 $\mathbf{H}^m \in \mathbb{R}^{|\mathcal{V}^m| \times |\mathcal{E}^m|}$ 表示节点与边之间的关联关系。对于第 t 个群组 g_t，我们将其表示为第 t 条超边 $e_t \in \mathcal{E}^m$，并将其连接到相应的成员节点和物品节点，即，如果节点 $v_s \in \mathcal{G}_t \cup \mathcal{Y}_t$，则 $\mathbf{H}^m(s, t) = 1$；其中 $\mathcal{G}_t$ 和 $\mathcal{Y}_t$ 分别指 g_t 的成员集合和交互集。例如，在图2中，由于群组 g_1 由 u_1 和 u_2 组成，并且与 i_1 和 i_2 交互，因此我们用连接其成员节点和物品节点的超边 e_1 表示群组 g_1。

4.1.2 物品级。 有时，可以从群组交互过的物品中推断出群组的共识。例如，在图1中，我们可以根据群组的交互历史得出该群组对爱情电影的共同偏好。因此，为了捕捉群组的物品级偏好，我们构建物品级视图，其中群组及其交互过的物品构成一个二部图。具体而言，我们将物品视图设计为图 $G^i = (\mathcal{V}^i, \mathcal{E}^i, \mathbf{A}^i)$，其中 $\mathcal{V}^i = \mathcal{G} \cup \mathcal{I}$ 表示节点集，$\mathcal{E}^i$ 表示边集 $\mathcal{E}^i = \{(g_t, i_j) | g_t \in \mathcal{G}\ i_j \in \mathcal{I}, \mathbf{Y}(t, j) = 1\}$，而 $\mathbf{A}^i \in \mathbb{R}^{(K+N) \times (K+N)}$ 是邻接矩阵

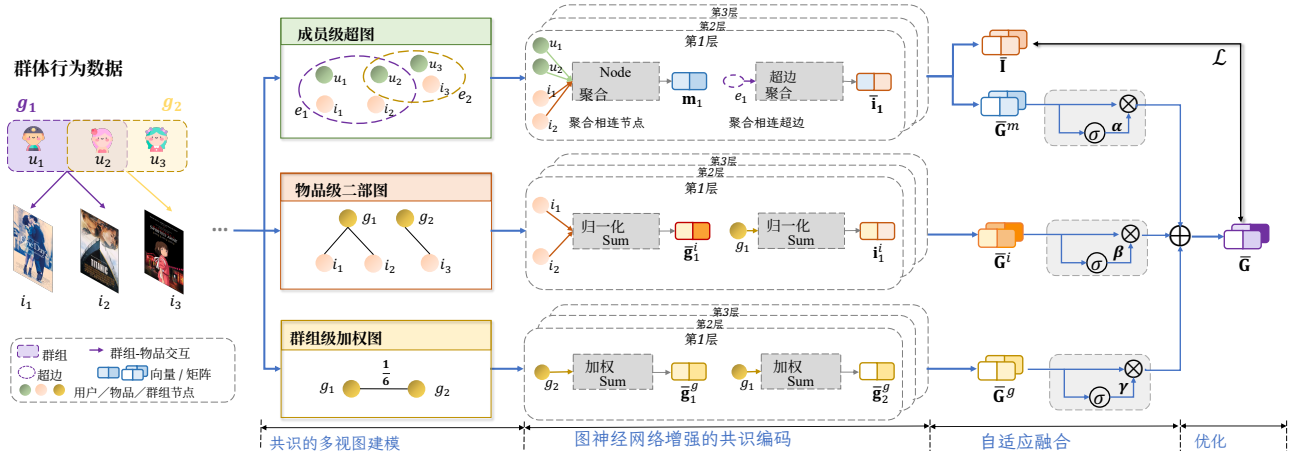


图2：ConsRec 概览。我们构建了三个不同的视图以进行共识建模，并采用特定的图神经网络进行表示学习。我们进一步整合这些特定视图的表示，用于群组-物品预测。

矩阵定义为 $\mathbf{A}^i = \begin{bmatrix} \mathbf{0} & \mathbf{Y} \\ \mathbf{Y}^T & \mathbf{0} \end{bmatrix}$。如图2所示，我们连接节点 g_2 和 i_3，因为群组 g_2 看过电影 i_3。

4.1.3 群组级。 在现实场景中，群组可能具有其固有偏好。例如，由一个家庭组成的群组往往喜欢观看家庭喜剧。为了捕捉并在相似群组之间传播此类信号，我们设计了群组级视图，将原本彼此孤立的群组连接起来。具体而言，每个群组都被建模为一个独立节点；如果不同群组至少共享一个成员或物品，就将它们连接起来。形式上，群组级图表示为 $G^g = (\mathbf{V}^g, \mathbf{E}^g, \mathbf{A}^g)$，其中 $\mathbf{V}^g = \mathbf{G}$ 且 $\mathbf{E}^g = \{(g_p, g_q) | g_p, g_q \in \mathbf{G}, |\mathbf{G}_p \cap \mathbf{G}_q| \geq 1 \text{或} |\mathbf{Y}_p \cap \mathbf{Y}_q| \geq 1\}$。我们利用邻接矩阵 $\mathbf{A}^g$ 来区分群组之间的相关性，即为每条边 (g_p, g_q) 分配权重 $\mathbf{A}^g(p, q) = \frac{|\mathbf{G}_p \cap \mathbf{G}_q| + |\mathbf{Y}_p \cap \mathbf{Y}_q|}{|\mathbf{G}_p \cup \mathbf{G}_q| + |\mathbf{Y}_p \cup \mathbf{Y}_q|}$。例如，如图2所示，由于 g_1和 g_2 共享一个成员，我们将这两个群组连接起来，并将权重计算为 $\frac{1+0}{3+3} = \frac{1}{6}$。

4.1.4 多视图建模。 本文旨在将用户、物品和群组嵌入到低维向量表示中。基于上述群体共识的多视图建模，我们可以将学习得到的 d维用户、物品和群组嵌入向量分别表示为矩阵 $\mathbf{U} \in \mathbb{R}^{M \times d}$、$\mathbf{I} \in \mathbb{R}^{N \times d}$ 和 $\mathbf{G} \in \mathbb{R}^{K \times d}$。这些矩阵可以通过以下图表示学习技术进行学习。

4.2 成员级超图网络

本小节介绍成员级视图，旨在获得有意义的成员级聚合，以估计共识。具体而言，我们设计了一种新颖的偏好感知超图神经网络，实现高效、公平且富有表现力的聚合方案。

4.2.1 偏好感知超图神经网络（*P-HGNN*）。我们将用户嵌入 $\mathbf{U} \in \mathbb{R}^{M \times d}$ 和物品嵌入 $\mathbf{I} \in \mathbb{R}^{N \times d}$ 输入超图神经网络。同时，由于我们将每个群组表示为一条超边 e，因此可以从群嵌入表 $\mathbf{G}$ 中获取其嵌入，表示为 $\mathbf{g}_e = \mathbf{G}(e,:)$。具体而言，我们的目标是通过超图传播获得精炼项目嵌入 $\mathbf{I}$ 以及群组的成员级表示 $\mathbf{G}^m$。接下来，我们将介绍该超图神经网络的具体设计，其示意过程如图3所示。

效率。 在超图神经网络中，[9, 36], 超边充当处理和传递信息的媒介。回顾一下，我们将成员级超图中的每个群组表示为一条超边，因此很自然地可以将卷积过程中超边传递的消息视为成员级聚合。与 [4, 5, 15, 16, 39] 所采用的穷举式、依赖候选项的注意力聚合相比，这种方式能够更高效地实现成员级聚合。

形式上，超边 $e \in \mathbf{E}^m$ 连接成员节点和物品节点，它们保留着不同的语义信息。因此，我们将物品聚合与用户聚合分开，以保持二者的区别。具体而言，对于超边 e，我们在其成员集 $\mathbf{G}_e$内计算成员聚合消息$\mathbf{m}_{e,u}$，即$\mathbf{m}_{e,u} = \text{AGG}_{node}(\{\mathbf{u}_s | u_s \in \mathbf{G}_e\})$。其中，$\text{AGG}_{node}(\cdot)$表示特定的节点聚合函数，$\mathbf{u}_s \in \mathbb{R}^d$ 表示第 s个用户的嵌入，即$\mathbf{u}_s = \mathbf{U}(s,:)$。同理，我们在交互集$\mathbf{Y}_e$ 内得到 e的物品侧消息$\mathbf{m}_{e,i}$，即$\mathbf{m}_{e,i} = \text{AGG}_{node}(\{\mathbf{i}_j | i_j \in \mathbf{Y}_e\})$，其中 $\mathbf{i}_j$表示第j个物品的嵌入，即$\mathbf{i}_j = \mathbf{I}(j,:)$。随后，我们可以直观地利用这些消息合成超边 e的表示$\mathbf{m}_e$。

公平性。 如图3所示，通常采用的注意力聚合会赋予活跃成员更高的权重，因此会导致聚合结果不公平 [23]。引入物品侧消息作为补充，有望缓解这一问题。此外，我们利用超边 e的独立表示$\mathbf{g}_e$ 与物品消息$\mathbf{m}_{e,i}$进行交互，以生成额外的协同信号。然后，我们通过线性变换融合这些不同的信息，如下所示：

$$\mathbf{m}_e = \text{CONCAT}(\mathbf{m}_{e,u}, \mathbf{m}_{e,i}, \mathbf{m}_{e,i} \odot \mathbf{g}_e)\mathbf{W}^f, \tag{1}$$

其中$\mathbf{m}_e$ 表示由 e携带的合成消息，$\odot$ 表示逐元素乘积，而 $\mathbf{W}^f \in \mathbb{R}^{3d \times d}$ 表示可训练的

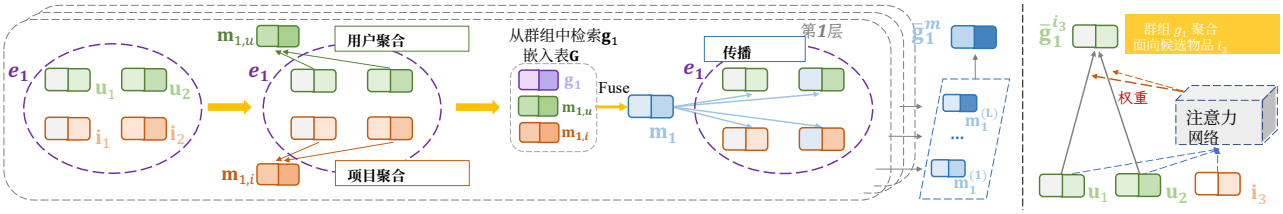


图3：我们提出的基于超图学习的聚合（左）与通常采用的注意力聚合（右）之间的比较。我们的方案在效率、公平性和表达能力方面均更胜一筹，具体说明见第4.2.2节。

用于消息融合的权重矩阵。经过此操作后，超边包含的消息能够更有意义且更少偏差地揭示成员与群组之间的共有信息。最后，我们可以通过收集节点 v 相关超边中的消息来优化其表示。形式上，对于目标物品节点 i_j，其表示更新如下：

$$\bar{\mathbf{i}}_j = \mathbf{AGG}_{he}(\{\mathbf{m}_e | e \in \mathcal{E}_j\}), \tag{2}$$

其中，$\bar{\mathbf{i}}_j$ 表示节点 i_j 的精炼嵌入，$\mathbf{AGG}_{he}(\cdot)$ 表示特定的超边聚合函数，$\mathbf{E}_j$ 表示与节点 i_j 相连的超边集合。至此，我们通过分别堆叠所有 $\bar{\mathbf{i}}_j (j = 1, ..., N)$ 和 $\mathbf{m}_e (e = 1, ..., K)$，完成了获得精炼物品嵌入 $\bar{\mathbf{I}}$ 和群组成员级表示 $\mathbf{G}^m$ 的目标。

表达能力。为提升表达能力，我们进一步将前述传播模块堆叠多层，使节点表示和超边消息都能受益于高阶邻居。最后，我们对每一层获得的嵌入取平均，以生成节点 i_j 的最终表示：

$$\bar{\mathbf{i}}_j = \frac{1}{L+1} \sum_{l=0}^{L} \mathbf{i}_j^{(l)},$$

其中，L 表示卷积层的总数，$\mathbf{i}_j^{(l)}$ 表示节点 i_j 在第 l 层的表示（我们有 $\mathbf{i}_j^{(0)} = \mathbf{i}_j$），后续层的计算可参照公式 1 和 2）。类似地，我们对每一层聚合的消息取平均，以生成超边（群组）e 的最终表示：

$$\bar{\mathbf{g}}_e^m = \frac{1}{L+1} \sum_{l=0}^{L} \mathbf{m}_e^{(l)},$$

其中，$\bar{\mathbf{g}}_e^m$ 表示群组 e 的成员级偏好，$\mathbf{m}_e^{(l)}$ 表示 e 在第 l 层所包含的消息，可通过公式 1 计算。将所有 $\bar{\mathbf{g}}_e^m (e = 1, ..., K)$ 堆叠起来，即可得到群组的成员级表示 $\bar{\mathbf{G}}^m$。此外，鉴于平均池化简单且有效，我们用它来实现 $\mathbf{AGG}_{node}(\cdot)$ 和 $\mathbf{AGG}_{he}(\cdot)$。

4.2.2 讨论。 我们将自身的聚合方法与 [4, 5, 11, 15, 16, 39] 采用的现有注意力聚合方法进行比较。示例如图3所示。给定一个候选物品，注意力方法首先将成员和物品表示拼接后输入注意力网络，以计算注意力权重；然后根据这些权重对成员求和，从而获得群组表示。考虑到现实场景中候选物品数量庞大，这种依赖候选物品的方法并不可行。此外，这种方式容易为活跃成员分配更高的权重，从而导致聚合结果有偏。相比之下，我们的聚合方案在效率方面更具优势，因为它通过超图卷积操作实现聚合；在公平性方面更具优势，因为它引入侧信息作为补充；在表达能力方面也更强，因为它融合了高阶协同信息。

4.3 物品级图网络

回顾一下，我们设计了群组-物品二部图 G^i，以根据物品级兴趣建模共识。在本小节中，我们旨在利用图神经网络 [13, 17] 捕获群组与物品之间的协同信号，最终获得群组在物品级上的判别性表示。

我们将群组嵌入 $\mathbf{G} \in \mathbb{R}^{K \times d}$ 与物品嵌入 $\bar{\mathbf{I}} \in \mathbb{R}^{N \times d}$ 拼接后输入图卷积网络，记作 $\mathbf{E} = \begin{bmatrix} \mathbf{G} \\ \bar{\mathbf{I}} \end{bmatrix}$。参考谱图卷积 [13, 17, 34]，我们将第 l 层的图卷积定义为：

$$\mathbf{E}^{(l+1)} = \mathbf{D}^{-\frac{1}{2}} \mathbf{A}^i \mathbf{D}^{-\frac{1}{2}} \mathbf{E}^{(l)}, \tag{3}$$

其中，$\mathbf{E}^{(l)}$ 表示第 l 层的节点表示，$\mathbf{D}$ 是邻接矩阵 $\mathbf{A}^i$ 的对角节点度矩阵。我们将 $\mathbf{E}^{(0)} = \mathbf{E}$ 输入 L 卷积层，然后对每一层得到的嵌入取平均，获得最终嵌入 $\bar{\mathbf{E}} = \frac{1}{L+1} \sum_{l=0}^{L} \mathbf{E}^{(l)} = \begin{bmatrix} \bar{\mathbf{G}}^i \\ \bar{\mathbf{I}}^i \end{bmatrix}$。因此，可以将群组 e 的物品级共识表示为 $\mathbf{g}_e^i = \bar{\mathbf{G}}^i(e, :)$。如图2所示，在传播过程中，交互物品的信息被明确注入群组的物品级表示中，因此，得到的 $\bar{\mathbf{G}}^i$ 足以充分表达物品级偏好。

4.4 群组级图网络

由于构建的群组级图 G^g 描绘了群组之间的连接关系，我们仍采用图神经网络对不同群组之间的高阶关系进行编码。请注意，我们通过计算不同的权重来区分群组之间的相关性，使每个群组都能从最相关的邻居处吸收信息，从而增强其表达能力。

具体而言，我们将群组嵌入 $\mathbf{G} \in \mathbb{R}^{K \times d}$ 输入图卷积网络，记作 $\mathbf{G}^{(0)} = \mathbf{G}$。随后，每一层的传播机制与公式 3 类似。因此，

经过$\mathbf{G}^{(0)}$ L 个卷积层后，我们可以得到最终的群组级嵌入$\mathbf{G}^{g} = \frac{1}{L+1}\sum_{l=0}^{L}\mathbf{G}^{(l)}$。我们将$\mathbf{G}^{g}$视为群体层级内在偏好，因为它探索并保留了群组级邻近性。

4.5 自适应融合与优化

如前所述，我们从三个不同的视图对群组的共识进行了建模，包括成员级聚合$\mathbf{G}^{m}$、物品级兴趣$\mathbf{G}^{i}$以及群体层级内在偏好$\mathbf{G}^{g}$。接下来，核心问题是将这些视图融合起来，以获得群体共识的最终表示。为了自适应地控制三个视图专属群组表示的组合，我们提出采用以下三个不同的门控：

$$\overline{\mathbf{G}} = \boldsymbol{\alpha}\overline{\mathbf{G}}^{m} + \boldsymbol{\beta}\overline{\mathbf{G}}^{i} + \boldsymbol{\gamma}\overline{\mathbf{G}}^{g}, \tag{4}$$

其中，$\boldsymbol{\alpha} = \sigma(\overline{\mathbf{G}}^{m}\mathbf{W}^{m})$、$\boldsymbol{\beta} = \sigma(\overline{\mathbf{G}}^{i}\mathbf{W}^{i})$和$\boldsymbol{\gamma} = \sigma(\overline{\mathbf{G}}^{g}\mathbf{W}^{g})$。这里，$\mathbf{W}^{m}$、$\mathbf{W}^{i}$和$\mathbf{W}^{g} \in \mathbb{R}^{d}$是三个不同的可训练权重，$\sigma$是激活函数。$\boldsymbol{\alpha}$，$\boldsymbol{\beta}$和$\boldsymbol{\gamma}$表示学习得到的权重，分别用于平衡成员级、物品级和群组级信息的贡献。基于此，我们可以获得最终的群组表示$\mathbf{G}$。在优化过程中，凭借丰富的监督信号，我们的模型能够自动判断不同视图的重要性。

接下来，我们介绍一种同时学习用户-物品交互和群组-物品交互的优化策略。详细的训练过程如算法1所示。对于群组-物品对(g_t, i_j)，我们将其对应的表示输入多层感知机（MLP）[28]，以计算最终预测分数$\hat{y}_{t,j}$，即$\hat{y}_{tj} = \mathbf{MLP}(\mathbf{g}_t \odot \mathbf{i}_j)$，其中，$\mathbf{g}_t = \overline{\mathbf{G}}(t, :)$表示目标群组$g_t$的最终群组表示，$\mathbf{i}_j = \mathbf{I}(j, :)$表示候选物品$i_j$经精炼后的嵌入，$\mathbf{MLP}(\cdot)$的输入维度设为$d$，输出维度设为1。利用群组-物品交互数据，我们采用贝叶斯个性化排序（BPR）损失 [27] 进行优化，如下所示：

$$\mathcal{L}_{group} = -\sum_{g_t \in \mathcal{G}} \frac{1}{|\mathcal{D}_{g_t}|} \sum_{(j,j') \in \mathcal{D}_{g_t}} \ln \sigma(\hat{y}_{tj} - \hat{y}_{tj'}), \tag{5}$$

其中，$\mathbf{D}_{g_t}$表示为群组g_t采样的群组-物品训练集，其中每个实例都是一对(j, j')，表示群组g_t与物品i_j发生过交互，但未与物品$i_{j'}$发生交互。

为进一步利用监督信号，我们提出纳入用户-物品交互数据，同时优化群组-物品和用户-物品任务。类似地，对于用户-物品对(u_s, i_j)，我们计算预测分数$\hat{r}_{sj} = \mathbf{多层感知机}(\mathbf{u}_s \odot \mathbf{i}_j)$，其中**多层感知机**$(\cdot)$与群组-物品多层感知机网络共享，$\mathbf{u}_s$和$\mathbf{i}_j$分别表示相应用户和物品的嵌入。我们采用相同的成对损失函数进行优化，具体如下：

$$\mathcal{L}_{user} = -\sum_{u_s \in \mathcal{U}} \frac{1}{|\mathcal{D}_{u_s}|} \sum_{(j,j') \in \mathcal{D}_{u_s}} \ln \sigma(\hat{r}_{sj} - \hat{r}_{sj'}), \tag{6}$$

其中，$\mathbf{D}_{u_s}$表示为用户u_s采样的用户-物品训练集，(j, j')表示用户u_s更偏好观测到的物品i_j而非未观测到的物品$i_{j'}$。我们在所有群组-物品和用户-物品交互上联合训练$\mathbf{L}_{group}$和$\mathbf{L}_{user}$，即$\mathbf{L} = \mathbf{L}_{group} + \mathbf{L}_{user}$。

表1：数据集统计信息。

数据集	#用户	#物品	#群组	#U-I 交互	#G-I 交互
马蜂窝	5,275	1,513	995	39,761	3,595
CAMRa2011	602	7,710	290	116,344	145,068

5 实验

本节将介绍我们的实验设置和实证结果。我们的实验旨在回答以下研究问题（RQs）：

- **RQ1：** 我们提出的 ConsRec 与各种群组推荐方法相比，表现如何?
- **RQ2：** 所提出的不同视图是否能够捕获共识信息并提供更好的推荐?
- **研究问题3：** 与其他群组推荐技术相比，我们的方法效率如何?
- **RQ4：** 我们的偏好感知超图神经网络（P-HGNN）效果如何?
- **RQ5：** 不同的超参数设置会如何影响模型性能?

由于篇幅限制，我们将研究问题4和5移至附录。

5.1 实验设置

5.1.1 数据集。 我们在两个真实世界的公开数据集 Mafengwo 和 CAMRa2011 [4]上进行实验。具体而言，Mafengwo 是一个旅游网站，用户可以记录自己去过的地点，并创建或加入团体旅行。CAMRa2011 是一个真实世界数据集，包含个人用户和家庭的电影评分记录。表1报告了实验数据集的详细统计信息。

5.1.2 基线方法。 为评估 ConsRec 的有效性，我们将其与以下具有代表性的方法进行比较。受篇幅限制，我们仅展示这些方法所属的类别，并将详细信息放在附录 B.3 中。请注意，这些类别之间存在重叠。例如，基线方法 S^2-HHGR [39] 同时融合了超图学习和自监督学习。

- **非个性化方法**：流行度（Pop） [8]
- **基于经典神经网络的方法**：NCF [14]
- **注意力聚合方法**：AGREE [4]
- **超图学习增强型**：HyperGroup [11],HCR [16]
- **自监督学习增强型**：GroupIM [29], $\mathbf{S}^2$-HHGR[39], 和 CubeRec [6]

5.1.3 评估指标。沿用以往的设置 [4, 5, 16],，我们采用衡量 Top-K 推荐效果的两种常用评估指标，即即命中率（HR）和归一化折损累计增益（NDCG）。HR 和 NDCG 越高，表示性能越好。为避免将所有物品都作为候选项带来的巨大计算开销，我们为每个真实物品随机采样 100 个负样本物品，并根据计算出的交互概率 [4, 16]对它们进行排序。我们使用相同的指标和测试数据评估所有方法的性能。受篇幅限制，数据预处理和实现细节移至附录 B.2。

表 2：所有方法在群组推荐任务上的性能比较，采用 HR@K 和 NDCG@K 指标。

数据集	指标	Pop	NCF	AGREE	HyperGroup	HCR	GroupIM	S^2-HHGR	CubeRec	**ConsRec**
马蜂窝	HR@5	0.3115	0.4701	0.4729	0.5739	0.7759	0.7377	0.7568	0.8613	**0.8844**
	HR@10	0.4251	0.6269	0.6321	0.6482	0.8503	0.8161	0.7779	0.9025	**0.9156**
	NDCG@5	0.2169	0.3657	0.3694	0.4777	0.6611	0.6078	0.7322	0.7574	**0.7692**
	NDCG@10	0.2537	0.4141	0.4203	0.5018	0.6852	0.6330	0.7391	0.7708	**0.7794**
CAMRa2011	HR@5	0.4324	0.5803	0.5879	0.5890	0.5883	**0.6552**	0.6062	0.6400	0.6407
	HR@10	0.5793	0.7693	0.7789	0.7986	0.7821	**0.8407**	0.7903	0.8207	0.8248
	NDCG@5	0.2825	0.3896	0.3933	0.3856	0.4044	0.4310	0.3853	0.4346	**0.4358**
	NDCG@10	0.3302	0.4448	0.4530	0.4538	0.4670	0.4914	0.4453	0.4935	**0.4945**

表3：性能 用户推荐任务中所有方法在 HR@K 和 NDCG@K 方面的比较 .

数据集	指标	Pop	NCF	AGREE	HyperGroup	HCR	GroupIM	S^2-HHGR	CubeRec	**ConsRec**
马蜂窝	HR@5	0.4047	0.6363	0.6357	0.7235	0.7571	0.1608	0.6380	0.1847	**0.7725**
	HR@10	0.4971	0.7417	0.7403	0.7759	0.8290	0.2497	0.7520	0.3734	**0.8404**
	NDCG@5	0.2876	0.5432	0.5481	0.6722	0.6703	0.1134	0.4637	0.1099	**0.6884**
	NDCG@10	0.3172	0.5733	0.5738	0.6894	0.6937	0.1420	0.5006	0.1708	**0.7107**
CAMRa2011	HR@5	0.4624	0.6119	0.6196	0.5728	0.6262	0.6113	0.6153	0.5754	**0.6774**
	HR@10	0.6026	0.7894	0.7897	0.7601	0.7924	0.7771	0.8173	0.7827	**0.8412**
	NDCG@5	0.3104	0.4018	0.4098	0.4410	0.4195	0.4064	0.3978	0.3751	**0.4568**
	NDCG@10	0.3560	0.4535	0.4627	0.5016	0.4734	0.4606	0.4641	0.4428	**0.5104**

5.2 整体性能（RQ1）

我们将 ConsRec 的性能与所有基线方法进行比较。表 2 和表 3 分别展示了群组推荐任务和用户推荐任务上的实验结果。根据结果，我们总结出以下关键观察：

• 对于表2所示的群组推荐任务，ConsRec 在两个基准数据集上的大多数评估指标中均优于所有基线方法。我们将这一优势归因于所提出的三种新颖的共识建模视图，它们以最全面的方式捕捉群组偏好。

• 在所有基线方法中，超图学习增强模型（Hy- perGroup [11] 和 HCR [16]）的表现优于经典聚合方法（AGREE [4]），这表明捕捉高阶协同信息的必要性。此外，S^2-HHGR [39] 和 CubeRec [6] 由于引入了自监督学习目标而取得了进一步提升。尽管如此，我们的模型仍实现了最佳性能。

• 对于表3所示的用户推荐任务，我们的模型仍具有优势。我们将此归因于我们的优化策略，该策略能够同时提升群组推荐和用户推荐的性能。值得注意的是，GroupIM [29] 和 CubeRec [6], 虽然在群组推荐上表现理想，但在用户推荐上的表现却不佳。这是因为它们将用户-物品和群组-物品训练分开进行，牺牲用户推荐的性能来过拟合群组推荐。

5.3 共识学习的有效性（ 共识学习的有效性（ RQ2)

5.3.1 多视图建模。为捕捉群体共识，我们创新性地设计了三个视图，包括成员级聚合、物品级兴趣和群体层级内在偏好。为了验证

表4：不同视图的消融研究，并报告群体推荐结果。“w/o. M”、“w/o. I”和“w/o. G”分别指去除成员级、物品级和群组级视图的变体。

数据集	指标	不使用 M	不使用 I	不含 G	**Full**
马蜂窝	HR@5	0.8201	0.8704	0.8593	**0.8844**
	HR@10	0.8724	0.9075	0.9005	**0.9156**
	NDCG@5	0.7021	0.7597	0.7376	**0.7692**
	NDCG@10	0.7192	0.7718	0. 7510	**0.7794**

为了探究每个视图是否捕捉到了群组信息的不同方面，我们进一步进行了消融研究。具体而言，每次移除一个视图，仅按照与公式4相同的自适应融合机制融合其余两个视图。这三种变体分别记为“w/o. M”、“w/o. I”和“w/o. G”。实验结果见表4。由于篇幅所限，我们仅列出马蜂窝上的结果，因为CAMRa2011呈现出相似的性能模式。从表中可以观察到，移除任何一个视图都会导致性能下降，这表明每个视图在捕捉共识方面都发挥着独特作用。

5.3.2 案例研究。我们进一步进行案例研究，以探究 ConsRec 如何在具体示例中捕捉共识信息。然而，我们的两个实验数据集都不包含任何语义信息（例如物品名称或内容），无法帮助提升可解释性。因此，我们从马蜂窝官方网站额外爬取了一个数据集。该数据集名为“Mafengwo-S”，其中“S”代表语义。详细的爬取流程见附录B.1.2。最终，我们获得了一个包含 11,027 名用户、1,215 个群组和 1,236 个物品的新数据集。此外，每个物品都有独特的语义信息，即地点。为进行比较，我们只

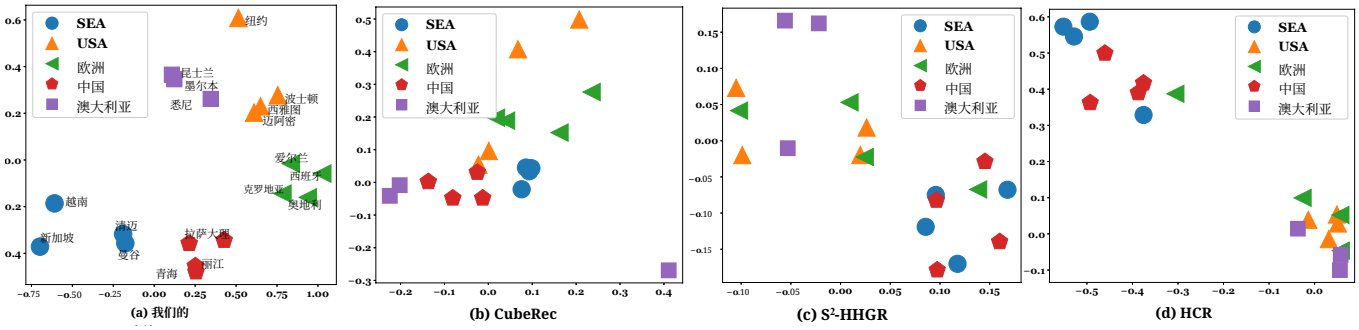


图 4：学习到的物品嵌入可视化。我们绘制了 Mafengwo-S 上物品表示的两个维度。ConsRec 学习物品的潜在属性，使地理位置相似的物品在嵌入空间中彼此靠近。



图 5：Mafengwo-S 上的案例研究。群组及其成员都曾到访过欧洲城市。ConsRec 捕捉到了这一共识，并推荐了符合真实情况的匈牙利。相比之下，HCR、GroupIM、S²-HHGR 和 Cu-beRec 受到一名成员偏好的影响，倾向于冰岛，并推荐了不令人满意的岛屿或沿海城市。

考虑 HCR [16], GroupIM [29], S²-HHGR [39], 和 CubeRec [6]，因为已有结果表明其他基线方法的性能较差。

如图 5 所示，这是一个由三名成员组成的群组，成员和群组都曾到访过欧洲城市。ConsRec 捕捉到了群组对欧洲城市的共识，并推荐了符合真实情况的匈牙利。HCR、GroupIM、S²-HHGR 和 CubeRec 则受到一名成员对冰岛的偏好影响，进而推荐了不令人满意的岛屿。

此外，我们还研究了不同方法学习到的物品（旅行地点）表示。由于 GroupIM [29] 不维护物品嵌入表，因此我们仅比较 ConsRec 与 HCR [16], S²-HHGR [39], 和 CubeRec [6]。具体而言，我们从东南亚（SEA）、美国、欧洲、中国和澳大利亚选取不同地点，并在图4中将其对应的嵌入可视化。值得注意的是，ConsRec 能够学习物品的潜在属性，因为地理位置相似的物品在嵌入空间中彼此接近。相比之下，其他基线方法学习到的嵌入区分度较低。

我们还展示了群组推荐任务的整体性能比较。从表5可以看出，ConsRec 的表现始终优于其他强大的基线方法，体现了其优越性。

5.4 效率研究（研究问题3）

我们通过直接比较 ConsRec 与所有基线方法的总运行时间（训练加测试）来评估其效率。图

表5：Mafengwo-S数据集上群组推荐任务的性能比较。

指标	HCR	GroupIM	S²-HHGR	CubeRec	**ConsRec**
HR@5	0.4845	0.5824	0.5928	0.6237	**0.6409**
HR@10	0.6099	0.6959	0.6546	0.6873	**0.6993**
NDCG@5	0.3947	0.4591	0.5348	0.5357	**0.5447**
NDCG@10	0.4353	0.4983	0.5545	0.5567	**0.5642**

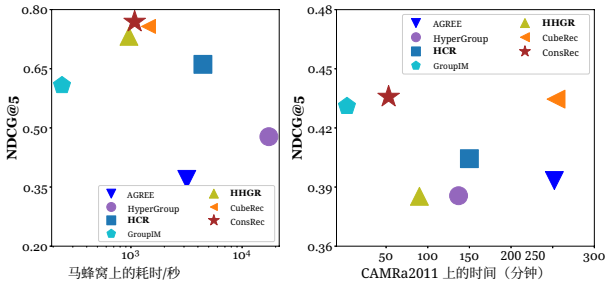


图 6：效率研究

6 展示了两个实验数据集上的性能（NDCG@5）和运行时间（秒或分钟）。值得注意的是，在各种群体推荐基线方法中，我们的方法效率相当高，同时取得了最佳性能。在 CAMRa2011 上，我们的优势更为明显。由于 CAMRa2011 比马蜂窝稠密得多，这一现象表明我们在降低较大数据集上的计算开销方面具有优势。

6 结论

本文揭示了群组决策背后的共识，并提出了一种新颖的推荐器 ConsRec。为捕获共识信息，ConsRec 设计了三种新颖的视图，包括成员级聚合、物品级偏好和群组层级内在偏好。特别是在成员级视图中，我们利用超图学习实现了高效且具有表达力的成员级聚合。在两个真实世界数据集上的大量实验表明，ConsRec 具有良好的有效性和效率。

致谢

本研究还得到中国国家自然科学基金项目（项目编号：U1936213）的部分支持，以及美国国家科学基金会通过以下资助项目提供的支持：IIS-1763365、IIS-2106972、III-1763325、III-1909323、III-2106758 和 SaTC-1930941。

参考文献

[1] Sihem Amer-Yahia、Senjuti Basu Roy、Ashish Chawla、Gautam Das 和 Cong Yu。2009。群体推荐：语义与效率。Proc. VLDB Endow. 2 (2009)，754–765。[2] Linas Baltrunas、Tadas Makcinskas 和 Francesco Ricci。2010。结合排序聚合与协同过滤的群组推荐。载于 RecSys '10。[3] Ludovico Boratto 和 Salvatore M. Carta。2011。群组推荐的最新进展及群组自动识别的新方法。载于《分布式环境中的信息检索与挖掘》。[4] Da Cao、Xiangnan He、Lianhai Miao、Yahui An、Chao Yang 和 Richang Hong。2018。注意力群组推荐。第41届国际 ACM SIGIR 信息检索研究与开发会议（2018）。[5] Da Cao、Xiangnan He、Lianhai Miao、Guangyi Xiao、Hao Chen 和 Jiao Xu。2021。社交增强型注意力群组推荐。TKDE 33 (2021)，1195–1209。[6] Tong Chen、Hongzhi Yin、Jing Long、Quoc Viet Hung Nguyen、Yang Wang 和 Meng Wang。2022。盒中求索：学习用于群体推荐的超立方体表示。第45届国际 ACM SIGIR 信息检索研究与开发会议论文集（2022）。[7] Dian Cheng、Jiawei Chen、Wen-Chih Peng、Wen Ye、Fuyu Lv、Tao Zhuang、Xiaoyi Zeng 和 Xiangnan He。2022。IHGNN：用于个性化商品搜索的交互式超图神经网络。2022年 ACM Web 会议论文集（2022）。[8] Paolo Cremonesi、Yehuda Koren 和 Roberto Turrin。2010。推荐算法在 Top-N 推荐任务中的表现。载于 RecSys '10。[9] Yifan Feng、Haoxuan You、Zizhao Zhang、R. Ji 和 Yue Gao。2019。超图神经网络。ArXiv abs/1809.09401（2019）。[10] Xavier Glorot 和 Yoshua Bengio。2010。理解深度前馈神经网络训练的难点。载于 AISTATS。[11] Lei Guo、Hongzhi Yin、Tong Chen、Xiangliang Zhang 和 Kai Zheng。2022。用于群体推荐的基于分层超边嵌入的表示学习。ACM 信息系统汇刊 40 (2022)，3:1–3:27。[12] Lei Guo、Hongzhi Yin、Qinyong Wang、Bin Cui、Zi Huang 和 Li zhen Cui。2020。基于潜在投票机制的群组推荐。2020年 IEEE 第36届数据工程国际会议（ICDE）（2020），121–132。[13] Xiangnan He、Kuan Deng、Xiang Wang、Yan Li、Yongdong Zhang 和 Meng Wang。2020。LightGCN：简化并增强用于推荐的图卷积网络。第43届国际 ACM SIGIR 信息检索研究与开发会议论文集（2020）。[14] Xiangnan He、Lizi Liao、Hanwang Zhang、Liqiang Nie、Xia Hu 和 Tat-Seng Chua。2017。神经协同过滤。第26届万维网国际会议论文集（2017）。[15] Zhixiang He、Chi-Yin Chow 和 Jiadong Zhang。2020。GAME：学习用于临时群组推荐的图结构注意力多视图嵌入。第43届国际 ACM SIGIR 信息检索研究与开发会议论文集（2020）。[16] Renqi Jia、Xiaofei Zhou、Linhua Dong 和 Shirui Pan。2021。用于群体推荐的超图卷积网络。2021年 IEEE 国际数据挖掘会议（ICDM）（2021），260–269。[17] Thomas Kipf 和 Max Welling。2017。基于图卷积网络的半监督分类。ArXiv abs/1609.02907（2017）。[18] Congcong Li、Yucheng Dong 和 Francisco Herrera。2019。用于大规模语言群体决策的共识模型：基于聚类个性化个体语义和对立共识群体的反馈推荐。IEEE 模糊系统汇刊 27 (2019)，221–233。[19] Qimai Li、Zhichao Han 和 Xiao-Ming Wu。2018。深入理解用于半监督学习的图卷积网络。载于 AAAI。[20] Xingjie Liu、Yuan Tian、Mao Ye 和 Wang-Chien Lee。2012。探究个人影响在群组推荐中的作用。第21届 ACM 国际信息与知识管理会议论文集（2012）。[21] Yujia Liu、Changyong Liang、Francisco Chiclana 和 Jian Wu。2017。一种信任驱动的推荐机制，用于在群体决策中达成共识制作。《Knowledge-Based Systems》119（2017），221–231。[22] Chen Ma、Peng Kang 和 Xue Liu。2019。用于序列推荐的层次化门控网络。第25届ACM SIGKDD知识发现与数据挖掘国际会议论文集（2019）。[23] André F. T. Martins 和 Ramón Fernández Astudillo。2016。从 Softmax 到 Sparsemax：一种用于多标签分类的稀疏注意力模型。载于 ICML。[24] Liqiang Nie、Meng Wang、Yue Gao、Zhengjun Zha 和 Tat-Seng Chua。2013。超越文本问答：通过挖掘网络信息生成多媒体答案。IEEE多媒体汇刊 15（2013），426–441。[25] Liqiang Nie、Yi-Liang Zhao、Xiangyu Wang、Jialie Shen 和 Tat-Seng Chua。2014。学习为社交论坛中的问题推荐描述性标签。ACM 信息系统汇刊 32（2014），5:1–5:23。[26] Hongyu Ren、Weihua Hu 和 Jure Leskovec。2020。Query2box：使用盒嵌入在向量空间中对知识图谱进行推理。ArXiv abs/2002.05969（2020）。[27] Steffen Rendle、Christoph Freudenthaler、Zeno Gantner 和 Lars Schmidt-Thieme。2009。BPR：基于隐式反馈的贝叶斯个性化排序。ArXiv abs/1205.2618（2009）。[28] Frank Rosenblatt。1963。《神经动力学原理》。感知机与脑机制理论。《美国心理学杂志》76（1963），705。[29] Aravind Sankar、Yanhong Wu、Yuhang Wu、Wei Zhang、Hao Yang 和 H. Sundaram。2020。GroupIM：一种用于神经群组推荐的互信息最大化框架。第43届 ACM SIGIR 信息检索研究与发展国际会议论文集（2020）。[30] Young-Duk Seo、Young-Gab Kim、Euijong Lee、Kwangsoo Seol 和 Doo-Kwon Baik。2018。考虑偏差的增强型群组推荐聚合方法。《专家系统与应用》93（2018），299–312。[31] Lucas Vinh Tran、Tuan-Anh Nguyen Pham、Yi Tay、Yiding Liu、G. Cong 和 Xiaoli Li。2019。交互并决策：用于有效群组推荐的子注意力网络组合。第42届 ACM SIGIR 信息检索研究与发展国际会议论文集（2019）。[32] Ashish Vaswani、Noam M. Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N. Gomez、Lukasz Kaiser 和 Illia Polosukhin。2017。注意力就是你所需要的一切。载于 NIPS。[33] Jianling Wang、Kaize Ding、Liangjie Hong、Huan Liu 和 James Caverlee。2020。基于序列超图的下一项目推荐。第43届 ACM SIGIR 信息检索研究与发展国际会议论文集（2020）。[34] Felix Wu、Tianyi Zhang、Amauri H. de Souza、Christopher Fifty、Tao Yu 和 Kilian Q. Weinberger。2019。简化图卷积网络。ArXiv abs/1902.07153（2019）。[35] Jiancan Wu、Xiang Wang、Fuli Feng、Xiangnan He、Liang Chen、Jianxun Lian 和 Xing Xie。2021。用于推荐的自监督图学习。第44届 ACM SIGIR 信息检索研究与发展国际会议论文集（2021）。[36] Naganand Yadati、Madhav Nimishakavi、Prateek Yadav、Vikram Nitin、Anand Louis 和 Partha Pratim Talukdar。2019。HyperGCN：一种在超图上训练图卷积网络的新方法。载于 NeurIPS。[37] Junliang Yu、Hongzhi Yin、Jundong Li、Qinyong Wang、Nguyen Quoc Viet Hung 和 Xiangliang Zhang。2021。用于社交推荐的自监督多通道超图卷积网络。2021年网络会议论文集（2021）。[38] Quan Yuan、G. Cong 和 Chin-Yew Lin。2014。COM：一种用于群组推荐的生成模型。第20届 ACM SIGKDD 知识发现与数据挖掘国际会议论文集（2014）。[39] Junwei Zhang、Min Gao、Junliang Yu、Lei Guo、Jundong Li 和 Hongzhi Yin。2021。用于群组推荐的双尺度自监督超图学习。第30届 ACM 信息与知识管理国际会议论文集（2021）。[40] Shuai Zhang、Huoyu Liu、Aston Zhang、Yue Hu、Ce Zhang、Yumeng Li、Tanchao Zhu、Shaojian He 和 Wenwu Ou。2021。利用超长方体学习推荐系统中的用户表示。第14届 ACM 网络搜索与数据挖掘国际会议论文集（2021）。[41] Kun Zhou、Haibo Wang、Wayne Xin Zhao、Yutao Zhu、Sirui Wang、Fuzheng Zhang、Zhongyuan Wang 和 Ji rong Wen。2020。S3-Rec：通过互信息最大化进行序列推荐的自监督学习。第29届 ACM 信息与知识管理国际会议论文集（2020）。

A 符号说明我们在表6中列出了本文使用的重要符号。

表6：重要符号

符号	说明
U, I, G	用户、物品和群组的集合
M, N, K	用户、物品和群组的数量
u_s, i_j, g_t	第 s个用户、第 j个物品和第 t个群组
$\mathbf{Y}$	群组-物品交互矩阵
$\mathbf{R}$	用户-物品交互矩阵
$\mathcal{G}_t$	第 t个群组的成员集合
$\mathcal{Y}_t$	第 t个群组的交互集
$\mathbf{U}, \mathbf{I}, \mathbf{G}$	用户、物品和群组的嵌入表
$G^m = (\mathbf{V}^m, \mathbf{E}^m, \mathbf{H}^m)$	成员级超图
e_t	第 t条超边，位于 G^m
$\mathbf{m}_{e,u}$	超边 e的聚合用户消息
$\mathbf{m}_{e,i}$	超边 e的聚合物品消息
$\mathbf{m}_e^{(l)}$	第 l层中超边 e 的消息
$\overline{\mathbf{G}}^m$	群组的成员级表示
$\overline{\mathbf{g}}_t^m = \overline{\mathbf{G}}^m(t,:)$	第 t个群组的成员级表示
$G^i = (\mathbf{V}^i, \mathbf{E}^i, \mathbf{A}^i)$	物品级二部图
$\overline{\mathbf{G}}^i$	组的项目级表示
$\mathbf{g}_t^i = \overline{\mathbf{G}}^i(t,:)$	第 t个群组的项目级表示
$G^g = (\mathbf{V}^g, \mathbf{E}^g, \mathbf{A}^g)$	群组级图
$\overline{\mathbf{G}}^g$	组级表示
$\mathbf{g}_t^g = \overline{\mathbf{G}}^g(t, :)$	第 t个群组的群组级表示
$\bar{\mathbf{I}}$	精炼项目嵌入
$\overline{\mathbf{G}}$	最终群组嵌入

算法1： ConsRec训练流程

输入： 用户集合 U、物品集合 I 和群组集合 G，群组-物品交互矩阵 Y，以及用户-物品交互矩阵**R**
输出： 所有模型参数统称为 Θ
随机初始化 Θ;
当 尚未收敛时 **执行**
  从 Y 中随机抽取 (g_t, i_j)，并采样负样本对于 g_t，构成 Dg_t，并计算群组预测损失 L$_{group}$ 关于 公式5;
  从 R 中随机抽取 (u_s, i_j)，并采样负样本以构成 Du_s，并计算用户预测损失 L$_{user}$ 相对于 公式 6;
  执行梯度步，以更新 Θ 相对于 L$_{group}$ + L$_{user}$;

B 可复现性

B.1 数据集

B.1.1 预处理。遵循先前的工作 [4, 5, 16], ，我们筛除成员至少为 2 人且与至少 3 个物品发生过交互的群组，以进行预处理。由于两个数据集都只包含正实例，即即已观测交互，我们从缺失数据中随机抽取负实例，与每个正实例配对。

B.1.2 爬取流程。对于马蜂窝上的群组页面，可以直接提取群组的旅行地点以及已加入成员的信息。然后，可以从每位成员的个人页面获取其个人访问记录。通过这种方式，我们可以收集群组级交互地点以及每位成员的访问地点。经过多次重复采集，可以构建一个包含丰富物品语义信息的新数据集。最终，我们得到一个由 11,027 位用户、1,215 个群组和 1,236 件物品组成的新数据集。该数据集命名为“Mafengwo-S”，其中“S”代表语义。

B.2 实现

我们使用 PyTorch 实现 ConsRec，并采用 Adam 优化器进行优化。对于嵌入层的初始化，我们采用 Glorot 初始化策略 [10]。对于隐藏层，我们使用均值为 0、标准差为 0.1 的高斯分布随机初始化其参数。对于超参数，我们调节卷积层的数量 L，取值范围为 {1，2，3，4}，并调节负实例的数量，取值范围为 {2，4，6，8，10，12}。根据经验，我们将嵌入维度设为 32。在预测层中，我们采用 3 层结构实现 **多层感知机**$(\cdot)$，并使用 ReLU 激活函数。

B.3 基线方法

我们将 ConsRec 与以下基线方法进行比较 :

• **Popularity** [8] 是一种非个性化方法，用于衡量其他个性化方法的性能。它根据物品在训练集中的交互次数（即物品的受欢迎程度）向用户和群组推荐物品。

• **NCF** [14] 将每个群组视为一个虚拟用户来进行预测。

• **AGREE** [4]是一种经典的基于注意力聚合的群组推荐方法，可有选择地聚合群组内用户的表示。

• **HyperGroup** [11] 将群组建模为超边，并提出了一种基于超边嵌入的表示学习方法。

• **HCR** [16] 是一个强大的群组推荐基线方法，提出了一种双通道超图卷积网络，用于捕捉成员级和群组级偏好。

• **GroupIM** [29] 通过注意力机制将用户偏好聚合为群组偏好。具体而言，为缓解数据稀疏性问题，该方法还增加了一项自监督学习目标，通过最大化用户与其所属群组之间的互信息来实现。

• **S^2-HHGR** [39] 是另一种强大的基线方法，它结合超图学习与自监督学习，以更好地预测群组偏好。

• **CubeRec** [6] 是群组推荐领域最先进的深度模型。它利用超立方体的几何表达能力，自适应地聚合成员兴趣。

为了进行性能比较，我们使用了它们在 GitHub 上发布的官方代码: NCF[3]、AGREE[4]、HCR[5]、GroupIM[6]、S^2-HHGR[7] 和 CubeRec[8]。由于 HyperGroup [11] 的源代码

[3] https://github.com/hexiangnan/neural_collaborative_filtering [4] https://github.com/LianHaiMiao/Attentive-Group-Recommendation [5] https://github.com/GroupRec/GroupRec [6] https://github.com/CrowdDynamicsLab/GroupIM [7] https://github.com/0411tony/HHGR [8] https://github.com/jinglong0407/CubeRec

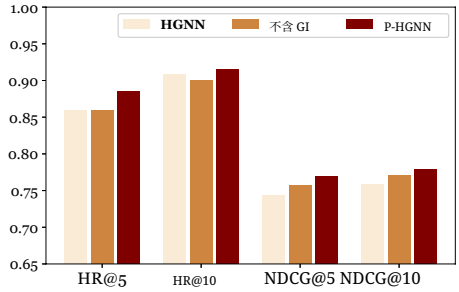


图7：在马蜂窝上对不同超图神经网络进行消融研究，并报告群组推荐结果。

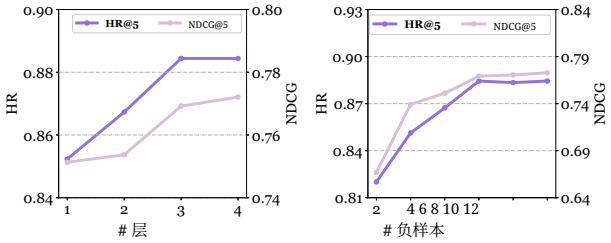


图8：马蜂窝数据集上群组推荐任务的参数研究。

无法获取，我们根据其原始论文实现了该方法。实际上，一些基线方法发布的代码存在问题或不完整，因此我们对其原始代码进行了重构。

为推动群组推荐的发展，我们在以下地址发布了ConsRec：https://github.com/FDUDSDE/WWW2023ConsRec。我们还发布了上述群体推荐基线方法的实现。对于所有基线模型，我们采用原论文报告的最佳参数设置。如果使用相同的数据集和评估设置，我们会直接报告其结果。所有实验均在配备32GB 内存的 Nvidia Tesla V100 GPU 机器上进行。

C 实验

C.1 P-HGNN 的有效性（RQ4）

回顾一下，我们提出了一种偏好感知超图神经网络，以实现表达能力更强的成员级聚合。具体计算机制如图3和公式1、2所示。为验证其有效性，我们通过与两个不同变体进行比较开展消融研究。其中一个是基础超图神经网络（HGNN）[36]。另一个变体移除了群组-物品逐元素乘积，即$\mathbf{m}_e = \textbf{拼接}(\mathbf{m}_{e,u}, \mathbf{m}_{e,i})\mathbf{W}^f$。该变体记为“w/o. GI”。

我们在图7中展示了实验结果。从图中可以看出，与“HGNN”相比，“w/o. GI”变体取得了更好的性能，表明保留用户和物品各自独特语义的必要性。我们的P-HGNN优于“w/o. GI”，说明引入群组-物品逐元素乘积是有效的。总之，P-HGNN能够生成更有意义的成员级聚合，从而增强群组的表示。

C.2 参数研究（RQ5）

在本小节中，我们研究模型中两个关键参数的影响，即（超）图卷积层的数量 L 以及负样本的数量。

C.2.1 卷积层数量。 图卷积网络的性能会受到图卷积层数量的影响。随着层数增加，卷积网络会面临过平滑问题 [19]，此时节点表示的判别性不足。为展示其影响，我们在图8中展示了性能关于 卷积层数量的变化。我们观察到，当层数为 3 时，马蜂窝上的结果更好。因此，我们选择 3 作为默认设置。

C.2.2 负样本数量。 负采样策略已被证明合理且有效 [22]。该策略会随机采样不同数量的缺失数据作为负样本，并与每个正样本配对。为展示负采样对我们模型的影响，我们在图8中展示了 ConsRec 的性能关于 不同负样本数量的变化。我们可以观察到，负样本过少不足以进行优化。随着负样本数量增加，模型性能先提升，随后趋于稳定。因此，我们选择 8 作为默认设置。

D 关于共识的讨论

尽管群体决策（GDM）任务中也研究了共识 [18, 21], ，但我们在此指出 GDM 任务与群组推荐（GR）任务之间的差异，以说明为何 GDM 方法不能直接应用于 GR 场景中的共识建模。

- 任务设定：GDM 要求将每个成员对所有备选项（即物品）的偏好作为输入，这依赖领域专业知识进行人工标注。相比之下，GR 任务会根据用户历史行为自动学习用户级偏好。
- 应用场景：由于严重依赖人工投入，GDM 仅适用于由特定群组从有限选项中进行选择的场景。相比之下，GR 任务能够处理包含大量物品和群组的大规模数据集。